



TUGAS AKHIR - SS141501

**PERAMALAN *INFLOW* DAN *OUTFLOW* UANG KARTAL
DI INDONESIA MENGGUNAKAN MODEL HIBRIDA
SINGULAR SPECTRUM ANALYSIS DAN *ADAPTIVE
NEURO FUZZY INFERENCE SYSTEM***

**ZUHROFATUL ULWIYAH
NRP 1314 100 095**

**Dosen Pembimbing
Imam Safawi Ahmad, M.Si
Dr. Suhartono**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2018**



TUGAS AKHIR - SS141501

**PERAMALAN *INFLOW* DAN *OUTFLOW* UANG KARTAL
DI INDONESIA MENGGUNAKAN MODEL HIBRIDA
SINGULAR SPECTRUM ANALYSIS DAN *ADAPTIVE
NEURO FUZZY INFERENCE SYSTEM***

**ZUHROFATUL ULWIYAH
NRP 1314 100 095**

**Dosen Pembimbing
Imam Safawi Ahmad, M.Si
Dr. Suhartono**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2018**



FINAL PROJECT - SS141501

**FORECASTING CURRENCY INFLOW AND OUTFLOW
IN INDONESIA USING HYBRID SINGULAR SPECTRUM
ANALYSIS AND ADAPTIVE NEURO FUZZY INFERENCE
SYSTEM**

**ZUHROFATUL ULWIYAH
NRP 1314 100 095**

**Supervisor
Imam Safawi Ahmad, M.Si
Dr. Suhartono**

**UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCES
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2018**

LEMBAR PENGESAHAN

PERAMALAN *INFLOW* DAN *OUTFLOW* UANG KARTAL DI INDONESIA MENGGUNAKAN MODEL HIBRIDA *SINGULAR SPECTRUM ANALYSIS* DAN *ADAPTIVE NEURO FUZZY INFERENCE SYSTEM*

TUGAS AKHIR

Diajukan untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Sains
pada

Program Studi Sarjana Departemen Statistika
Fakultas Matematika, Komputasi, dan Sains Data
Institut Teknologi Sepuluh Nopember

Oleh:

Zuhrofatul Ulwiyah

NRP. 1314 100 095

Disetujui oleh Pembimbing:

Imam Safawi Ahmad, M.Si

NIP. 19810224 201404 1 001

Dr. Suhartono

NIP. 19710929 199512 1 001

(Imam Safawi Ahmad)

(Dr. Suhartono)

Mengetahui,
Kepala Departemen

Dr. Suhartono

NIP. 19710929 199512 1 001

SURABAYA, JANUARI 2018

(Halaman ini sengaja dikosongkan)

**PERAMALAN *INFLOW* DAN *OUTFLOW* UANG KARTAL
DI INDONESIA MENGGUNAKAN MODEL HIBRIDA
SINGULAR SPECTRUM ANALYSIS DAN *ADAPTIVE
NEURO FUZZY INFERENCE SYSTEM***

Nama Mahasiswa : Zuhrofatul Ulwiyah
NRP : 06211440000095
Departemen : Statistika
Dosen Pembimbing 1 : Imam Safawi Ahmad, M.Si
Dosen Pembimbing 2 : Dr. Suhartono

Abstrak

Indikator jumlah uang beredar dapat dilihat melalui inflow dan outflow. Peramalan inflow dan outflow perlu dilakukan agar terjadi keseimbangan antara jumlah uang beredar dengan kebutuhan masyarakat. Peramalan yang tepat dijadikan informasi yang dapat dipertimbangkan oleh Bank Indonesia untuk perencanaan pengeluaran uang jangka pendek. Pada penelitian ini digunakan model hibrida singular spectrum analysis (SSA) dan adaptive neuro fuzzy inference system (ANFIS) untuk meramalkan inflow dan outflow uang kartal di Indonesia. Terdapat dua kajian yang digunakan yaitu kajian simulasi dan kajian terapan. Penelitian ini menggunakan data inflow dan outflow bulanan di Indonesia mulai bulan Januari 2003 sampai bulan Desember 2016. Hasil dari kajian simulasi menyatakan bahwa pola variasi kalender didekomposisi SSA dalam bentuk musiman atau noise serta peramalan agregat memberikan hasil yang lebih baik daripada peramalan individu. Peramalan SSA-ANFIS pada data pecahan inflow Rp 100.000,00, Rp 20.000,00, Rp 10.000,00, Rp 2.000,00, Rp 1.000,00 dan pecahan outflow Rp 1.000,00 menunjukkan peforma yang lebih baik jika dibandingkan dengan metode ARIMAX.

Kata Kunci : ANFIS, ARIMAX, Inflow, Outflow, SSA.

(Halaman ini sengaja dikosongkan)

FORECASTING CURRENCY INFLOW AND OUTFLOW IN INDONESIA USING HYBRID SINGULAR SPECTRUM ANALYSIS AND ADAPTIVE NEURO FUZZY INFERENCE SYSTEM

Name : Zuhrofatul Ulwiyah
NRP : 06211440000095
Department : Statistics
Supervisor 1 : Imam Safawi Ahmad, M.Si
Supervisor 2 : Dr. Suhartono

Abstract

The indicator of money circulation can be seen through the inflow and outflow. Forecasting inflow and outflow is needed in order to balance the amount of money circulation with the public's necessary. An appropriate forecasting can serve as information which considered by Bank Indonesia for short-term money spending planning. This research use singular spectrum analysis (SSA) and adaptive neuro fuzzy inference system (ANFIS) model to predict the inflow and outflow of currency in Indonesia. There are two studies that are used, i.e simulation study and case study. This research uses inflow and outflow monthly data of Indonesia start from January 2003 until December 2016. The results from the simulation study showed that the calendar variations pattern decompose by SSA in seasonal or noise pattern. Then, SSA-ANFIS aggregate forecasting show better results than individual forecasting. SSA-ANFIS forecasting on inflow data of Rp 100,000.00, Rp. 20,000.00, Rp 10,000.00, Rp 2,000.00, Rp. 1,000.00 and outflow data of Rp 1,000.00, shows better performance than ARIMAX method.

Keywords : ANFIS, ARIMAX, Inflow, Outflow, SSA.

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur penulis panjatkan atas rahmat dan hidayah yang diberikan Allah SWT sehingga penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul ***“Peramalan Inflow dan Outflow Uang Kartal di Indonesia Menggunakan Model Hibrida Singular Spectrum Analysis dan Adaptive Neuro Fuzzy Inference System”*** dengan lancar.

Penulis menyadari bahwa Tugas Akhir ini dapat terselesaikan tidak terlepas dari bantuan dan dukungan berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih kepada:

1. Bapak Dr. Suhartono selaku Kepala Departemen Statistika FMKSD ITS, dosen pembimbing Tugas Akhir, dan dosen wali yang telah meluangkan waktu dan memberikan bimbingan, saran, arahan serta motivasi selama proses belajar di Departemen Statistika.
2. Bapak Imam Safawi Ahmad, M.Si selaku dosen pembimbing Tugas Akhir yang telah memberikan bimbingan, saran dan dukungan selama penyusunan Tugas Akhir.
3. Bapak R. Moh. Atok, M.Si, Ph.D dan Bapak Dr. Ir. Setiawan, M.S selaku dosen penguji yang telah banyak memberi masukan kepada penulis sehingga Tugas Akhir ini dapat diselesaikan dengan baik.
4. Dr. Sutikno, M.Si selaku Ketua Program Studi Sarjana Departemen Statistika FMKSD ITS yang telah membantu secara administrasi dalam penyusunan Tugas Akhir.
5. Kedua orang tua penulis, Bapak Abdul Karim dan Ibu Nur Hidayati yang senantiasa mendoakan dan memberikan dukungan dengan tulus tiada henti.
6. Mas Abdur Rachman Hakim yang selalu memberikan doa, semangat dan dukungan sepenuh hati kepada penulis.
7. Rekan seperjuangan Tugas Akhir, Endah Setyowati dan Salafiyah Isnawati atas waktu, kebersamaan, nasihat dan motivasi dalam penyelesaian Tugas Akhir.

8. Kawan-kawan Muhyiddin *Foundation* yang telah memberikan dukungan dan semangat kepada penulis.
9. Teman-teman Statistika ITS angkatan 2014 atas dukungan dan kebersamaan selama proses belajar di Statistika ITS.
10. Semua pihak yang telah membantu baik secara langsung maupun tidak langsung dalam proses penyelesaian Tugas Akhir ini.

Penulis menyadari bahwa penyusunan Tugas Akhir ini masih memiliki banyak kekurangan. Besar harapan penulis untuk mendapatkan kritik dan saran yang membangun sehingga Tugas Akhir ini dapat memberikan manfaat bagi semua pihak yang terkait di kemudian hari.

Surabaya, Januari 2018

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
COVER PAGE	iii
LEMBAR PENGESAHAN Error! Bookmark not defined.	
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xx
DAFTAR LAMPIRAN	xxiii
DAFTAR NOTASI	xxv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	7
1.3 Tujuan	7
1.4 Manfaat	8
1.5 Batasan Masalah	8
BAB II TINJAUAN PUSTAKA	9
2.1 Analisis Deret Waktu	9
2.2 <i>Seasonal Autoregressive Integrated Moving Average (SARIMA)</i>	9
2.2.1 Identifikasi	10
2.2.2 Estimasi Parameter	11
2.2.3 Cek Diagnosa.....	14
2.2.4 Peramalan	15
2.3 <i>Autoregressive Integrated Moving Average with Exogenous Variable (ARIMAX)</i>	16
2.4 Uji Dickey-Fuller	18
2.5 <i>Singular Spectrum Analysis (SSA)</i>	18
2.5.1 Dekomposisi	19
2.5.2 Rekonstruksi	20
2.6 <i>Adaptive Neuro Fuzzy Inference System (ANFIS)</i>	22

2.6.1 Jaringan Adaptif.....	22
2.6.2 <i>Fuzzy Inference System</i> (FIS)	23
2.6.3 Fungsi Keanggotaan	25
2.6.4 Arsitektur ANFIS.....	28
2.7 <i>Singular Spectrum Analysis</i> dan <i>Adaptive</i> <i>Neuro Fuzzy Inference System</i>	31
2.8 Evaluasi Model	32
2.9 <i>Inflow</i> dan <i>Outflow</i> Uang Kartal	34
BAB III METODOLOGI PENELITIAN	35
3.1 Kajian Simulasi	35
3.2 Kajian Terapan.....	40
3.2.1 Sumber Data	40
3.2.2 Variabel Penelitian	41
3.2.3 Langkah Analisis.....	44
BAB IV ANALISIS DAN PEMBAHASAN	47
4.1 Kajian Simulasi	47
4.1.1 Skenario Pertama	49
4.1.2 Skenario Kedua.....	65
4.2 Karakteristik Data <i>Inflow</i> dan <i>Outflow</i> di Indonesia	78
4.3 Pemodelan Data <i>Inflow</i> dan <i>Outflow</i> dengan ARIMAX	83
4.4 Pemodelan Data <i>Inflow</i> dan <i>Outflow</i> dengan SSA-ANFIS	101
4.5 Pemilihan Metode Peramalan Terbaik	126
4.6 Peramalan dengan Metode Terbaik.....	131
BAB V KESIMPULAN DAN SARAN	137
5.1 Kesimpulan	137
5.2 Saran	138
DAFTAR PUSTAKA	139
LAMPIRAN	143
BIODATA PENULIS	229

DAFTAR GAMBAR

	Halaman
Gambar 2.1	Struktur <i>Fuzzy Inference System</i> (FIS)23
Gambar 2.2	Grafik Fungsi <i>Trapezoidal</i>26
Gambar 2.3	Grafik Fungsi <i>Generalized Bell</i>26
Gambar 2.4	Grafik Fungsi <i>Phi</i>27
Gambar 2.5	Grafik Fungsi <i>Gaussian</i>28
Gambar 2.6	Arsitektur ANFIS28
Gambar 2.7	Alur Peramalan Individu SSA-ANFIS31
Gambar 2.8	Alur Peramalan Agregat SSA-ANFIS.....32
Gambar 3.1	Diagram Alir Analisis Kajian Simulasi (SSA-ANFIS).....39
Gambar 3.2	Diagram Alir Algoritma Peramalan ANFIS.....40
Gambar 3.3	Diagram Alir Analisis Kajian Terapan.....45
Gambar 3.4	Diagram Alir Metode ARIMAX46
Gambar 4.1	<i>Time Series Plot</i> (a) Komponen <i>Trend</i> (b) Komponen Musiman (c) Efek Variasi Kalender.....47
Gambar 4.2	<i>Time Series Plot</i> (a) <i>Noise Random</i> (b) <i>Noise</i> Tidak <i>Random</i>48
Gambar 4.3	<i>Scatter Plot Noise Waktu ke-t dengan</i> <i>Noise Waktu ke t-1</i>48
Gambar 4.4	<i>Time Series Plot</i> Skenario Pertama49
Gambar 4.5	Plot Nilai Singular Skenario Pertama.....50
Gambar 4.6	Plot <i>Eigentriple</i> Utama pada Skenario Pertama.....51
Gambar 4.7	Plot Hasil Rekonstruksi (a) <i>Trend</i> (b) <i>Seasonality</i> (c) <i>Noise</i>52
Gambar 4.8	Plot PACF (a) <i>Differencing Trend</i> (b) <i>Noise</i> (c) <i>Seasonality</i> (d) <i>Differencing</i> <i>Seasonality</i> Skenario Pertama55
Gambar 4.9	Plot Hasil Ramalan Agregat SSA- ANFIS Skenario Pertama (a) <i>Trend</i> (b) <i>Seasonality</i> (c) <i>Noise</i> (d) Total57

Gambar 4.10	Plot PACF <i>Eigentriple</i> 1, 2, 3, ..., 11 dan <i>Noise</i> Skenario Pertama.....	59
Gambar 4.11	Hasil Ramalan SSA-ANFIS Individu Skenario Pertama.....	63
Gambar 4.12	Plot Perbandingan Hasil Ramalan Skenario Pertama.....	65
Gambar 4.13	<i>Time Series</i> Plot Skenario Kedua	66
Gambar 4.14	Plot Nilai Singular Skenario Kedua	67
Gambar 4.15	Plot <i>Eigentriple</i> Utama pada Skenario Kedua.....	67
Gambar 4.16	Plot Hasil Rekonstruksi (a) <i>Trend</i> (b) <i>Seasonality</i> (c) <i>Noise</i> pada Skenario Kedua	69
Gambar 4.17	Plot PACF (a) <i>Differencing Trend</i> (b) <i>Noise</i> (c) <i>Seasonality</i> (d) <i>Differencing Seasonality</i> Skenario Kedua	70
Gambar 4.18	Plot Hasil Ramalan Agregat SSA- ANFIS Skenario Kedua (a) <i>Trend</i> (b) <i>Seasonality</i> (c) <i>Noise</i> (d) Total	72
Gambar 4.19	Plot PACF <i>Eigentriple</i> 1, 2, 3, ..., 11 dan <i>Noise</i> Skenario Kedua	74
Gambar 4.20	Hasil Ramalan SSA-ANFIS Individu pada Skenario Kedua.....	76
Gambar 4.21	Plot Perbandingan Hasil Ramalan Skenario Kedua	77
Gambar 4.22	Plot Pola <i>Inflow</i> dan <i>Outflow</i> di Indonesia.....	78
Gambar 4.23	<i>Time Series</i> Plot <i>Inflow</i> dan <i>Outflow</i> per Pecahan di Indonesia.....	79
Gambar 4.24	Rata-Rata <i>Inflow</i> pada Bulan Terjadi dan Satu Bulan Setelah Hari Raya Idul Fitri.....	81
Gambar 4.25	Rata-Rata <i>Outflow</i> pada Bulan Terjadi dan Satu Bulan Setelah Hari Raya Idul Fitri.....	82
Gambar 4.26	Plot ACF Pecahan <i>Inflow</i> Rp 100.000,00.....	85

Gambar 4.27	Plot ACF Hasil <i>Differencing</i> Pecahan <i>Inflow</i> Rp 100.000,00.....	86
Gambar 4.28	Plot PACF Hasil <i>Differencing</i> Pecahan <i>Inflow</i> Rp 100.000,00.....	86
Gambar 4.29	<i>Time Series</i> Plot Perbandingan Hasil Ramalan ARIMAX per Pecahan <i>Inflow</i> dan <i>Outflow</i>	93
Gambar 4.30	Plot Nilai Singular Data <i>Inflow</i> Pecahan Rp 100.000,00	102
Gambar 4.31	Plot <i>Eigentriple</i> Utama pada Data <i>Inflow</i> Pecahan Rp 100.000,00.....	103
Gambar 4.32	Plot Hasil Rekonstruksi (a) <i>Trend</i> (b) <i>Seasonality</i> (c) <i>Noise</i> Pecahan <i>Inflow</i> Rp 100.000,00.....	104
Gambar 4.33	Plot PACF Pecahan <i>Inflow</i> Rp 100.000 (a) <i>Trend</i> (b) <i>Noise</i> (c) <i>Seasonality</i> (d) <i>Differencing Seasonality</i>	109
Gambar 4.34	Plot Hasil Ramalan (a) <i>Trend</i> (b) <i>Seasonality</i> (c) <i>Noise</i> pada Pecahan <i>Inflow</i> Rp 100.000,00.....	112
Gambar 4.35	Plot Hasil Ramalan SSA-ANFIS pada Pecahan <i>Inflow</i> Rp 100.000,00.....	113
Gambar 4.36	Struktur ANFIS Kelompok Pecahan <i>Inflow</i> Rp 100.000,00.....	114
Gambar 4.37	<i>Time Series</i> Plot Perbandingan Hasil Peramalan SSA-ANFIS per Pecahan <i>Inflow</i> dan <i>Outflow</i>	122
Gambar 4.38	Plot Perbandingan Hasil Peramalan Data <i>Out-Sample</i>	126
Gambar 4.39	Plot RMSE <i>Adaptive</i> Tiap Pecahan <i>Inflow</i> dan <i>Outflow</i> Uang Kartal	129
Gambar 4.40	Hasil Peramalan <i>Inflow</i> dan <i>Outflow</i> Uang Kartal di Indonesia dengan Metode Terbaik	131

Gambar 4.41 Grafik Besarnya Standar Deviasi yang
Direduksi pada Masing-Masing Model
Pecahan.....135

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

	Halaman
Tabel 2.1 Identifikasi Orde Model ARMA	11
Tabel 3.1 Variabel Penelitian.....	41
Tabel 3.2 Struktur Data <i>Inflow</i>	42
Tabel 3.4 Variabel <i>Dummy</i> yang Digunakan	42
Tabel 3.5 Identifikasi Variabel <i>Dummy</i> Variasi Kalender Idul Fitri Tahun 2003-2016.....	43
Tabel 4.1 Pengelompokan <i>Eigentruple</i> Skenario Pertama.....	52
Tabel 4.2 Uji Dickey-Fuller pada Data Skenario Pertama	54
Tabel 4.3 Uji Dickey-Fuller pada Data <i>Trend</i> Skenario Pertama Setelah <i>Differencing</i>	54
Tabel 4.4 Perbandingan RMSE <i>Out-Sample</i> Kelompok <i>Trend</i> , <i>Seasonality</i> , dan <i>Noise</i> pada Skenario Pertama	56
Tabel 4.5 Uji Dickey-Fuller Tiap <i>Eigentruple</i> Skenario Pertama	58
Tabel 4.6 Uji Dickey-Fuller Hasil <i>Differencing</i> Setiap <i>Eigentruple</i> Skenario Pertama	58
Tabel 4.7 Variabel <i>Input</i> Setiap <i>Eigentruple</i> pada Skenario Pertama	61
Tabel 4.8 Perbandingan RMSE <i>Out-Sample</i> Setiap <i>Eigen- triple</i> pada Skenario Pertama	62
Tabel 4.9 Model ANFIS Terbaik Setiap <i>Eigentruple</i> pada Skenario Pertama	63
Tabel 4.10 Pemilihan Model ANFIS Setiap <i>Eigentruple</i> pada Skenario Pertama.....	64
Tabel 4.11 Pengelompokan <i>Eigentruple</i> Skenario Kedua	68
Tabel 4.12 Uji Dickey-Fuller pada Data Skenario Kedua	70
Tabel 4.13 Perbandingan RMSE <i>Out-Sample</i> Kelompok <i>Trend</i> , <i>Seasonality</i> , dan <i>Noise</i> pada Skenario Kedua	71
Tabel 4.14 Uji Dickey-Fuller Setiap <i>Eigentruple</i> pada Skenario Kedua.....	73

Tabel 4.15	Uji Dickey-Fuller Hasil <i>Differencing Eigentriple</i> Skenario Kedua.....	73
Tabel 4.16	Variabel <i>Input</i> Setiap <i>Eigentriple</i> pada Skenario Kedua.....	75
Tabel 4.17	Model ANFIS Terbaik Setiap <i>Eigentriple</i> pada Skenario Kedua	76
Tabel 4.18	Pemilihan Model ANFIS Setiap <i>Eigentriple</i> pada Skenario Kedua.....	77
Tabel 4.19	Statistika Deskriptif Data <i>Inflow</i> (miliar Rp).....	82
Tabel 4.20	Statistika Deskriptif Data <i>Outflow</i> (miliar Rp)	83
Tabel 4.21	<i>Ljung-Box Test</i> untuk Residual Regresi per Pecahan	84
Tabel 4.22	Pemilihan Model ARIMAX Pecahan <i>Inflow</i> Rp 100.000,00.....	87
Tabel 4.23	Estimasi Parameter Model ARIMAX Pecahan <i>Inflow</i> Rp 100.000,00	87
Tabel 4.24	Model ARIMA Terbaik Pecahan <i>Inflow</i> dan <i>Outflow</i>	88
Tabel 4.25	Nilai Kebaikan Model ARIMAX per Pecahan <i>Inflow</i> dan <i>Outflow</i>	101
Tabel 4.26	Pengelompokan <i>Eigentriple</i> Data <i>Inflow</i> Pecahan Rp 100.000,00	103
Tabel 4.27	Uji Dickey-Fuller pada Data Pecahan <i>Inflow</i> Rp 100.000,00.....	105
Tabel 4.28	Uji Dickey-Fuller pada Data <i>Trend</i> Hasil <i>Differencing</i> untuk Pecahan <i>Inflow</i> Rp 100.000,00.....	105
Tabel 4.29	Uji Dickey-Fuller pada Data Pecahan <i>Inflow</i> dan <i>Outflow</i>	106
Tabel 4.30	Uji Dickey-Fuller pada Data Hasil <i>Differencing</i> Tiap Pecahan <i>Inflow</i> dan <i>Outflow</i>	108
Tabel 4.31	Variabel <i>Input</i> ANFIS Masing-Masing Kelompok pada Pecahan <i>Inflow</i> dan <i>Outflow</i>	110

Tabel 4.32	Perbandingan Nilai RMSE <i>Out-Sample</i> Model ANFIS untuk <i>Trend</i> , <i>Seasonality</i> , dan <i>Noise</i> Pecahan <i>Inflow</i> Rp 100.000,00.....	111
Tabel 4.33	Estimasi Awal Parameter Premis Fungsi <i>Phi</i> untuk ANFIS Kelompok <i>Trend</i> Pecahan <i>Inflow</i> Rp 100.000,00	115
Tabel 4.34	Estimasi Akhir Parameter Konsekuen Fungsi <i>Phi</i> Untuk ANFIS Kelompok <i>Trend</i> Pecahan <i>Inflow</i> Rp 100.000,00	116
Tabel 4.35	Estimasi Awal Parameter Premis Kelompok <i>Seasonality</i> dan <i>Noise</i> Pecahan <i>Inflow</i> Rp 100.000,00.....	116
Tabel 4.36	Perbandingan Kriteria Evaluasi Model Ramalan ARIMAX dan SSA-ANFIS Setiap Pecahan	128
Tabel 4.37	Periode Ramalan Terbaik Berdasarkan RMSE <i>Adaptive</i>	131
Tabel 4.38	Perbandingan RMSE Model dan Standar Deviasi	134

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Data <i>Inflow</i> dan <i>Outflow</i> di Indonesia.....	143
Lampiran 2 Surat Pernyataan Penggunaan Data Sekunder.....	144
Lampiran 3 Perbandingan RMSE <i>Out-Sample</i> Tiap <i>Eigentriple</i> pada Skenario Kedua.....	145
Lampiran 4 <i>Syntax</i> ARIMAX untuk Data <i>Inflow</i> Pecahan Rp 100.000,00 (dengan SAS)	146
Lampiran 5 Identifikasi Orde ARIMAX Data <i>Inflow</i> dan <i>Outflow</i> per Pecahan.....	147
Lampiran 6 <i>Output</i> SAS Uji Asumsi Model ARIMAX per Pecahan <i>Inflow</i> dan <i>Outflow</i> Uang Kartal.....	171
Lampiran 7 Estimasi Parameter Model ARIMAX per Pecahan <i>Inflow</i> dan <i>Outflow</i> Uang Kartal	178
Lampiran 8 <i>Output</i> SAS Hasil Ramalan <i>Out-Sample</i> <i>Inflow</i> Rp 100.000,00	191
Lampiran 9 <i>Syntax</i> SSA untuk Data <i>Inflow</i> Pecahan Rp 100.000,00 (dengan R)	192
Lampiran 10 Dekomposisi SSA per Pecahan <i>Inflow</i> dan <i>Outflow</i>	193
Lampiran 11 Plot PACF (a) <i>Trend</i> , (b) <i>Noise</i> , (c) <i>Seasonality</i> dan (d) <i>Differencing</i> Musiman Stasioner untuk Masing-Masing Kelompok pada Pecahan <i>Inflow</i> dan <i>Outflow</i>	206
Lampiran 12 <i>Syntax</i> ANFIS untuk Data <i>Inflow</i> Pecahan Rp 100.000,00 (dengan MATLAB)	213
Lampiran 13 Hasil Dekomposisi SSA dan Hasil Ramalan ANFIS pada Pecahan <i>Inflow</i> Rp 100.000,00	216

Lampiran 14	Pemilihan Model ANFIS Terbaik Pecahan <i>Inflow</i> dan <i>Outflow</i> dengan Jumlah Fungsi Keanggotaan 2.....	217
Lampiran 15	<i>Output</i> MATLAB Estimasi Parameter Model ANFIS Tiap Pecahan <i>Inflow</i> dan <i>Outflow</i>	224
Lampiran 16	Hasil Ramalan Pecahan <i>Inflow</i> Tahun 2017-2019 dengan Metode Peramalan Terbaik (Miliar Rupiah).....	227
Lampiran 17	Hasil Ramalan Pecahan <i>Outflow</i> Tahun 2017-2019 dengan Metode Peramalan Terbaik (Miliar Rupiah)	228

DAFTAR NOTASI

ARIMA dan ARIMAX

a_t	: Error model periode ke- t yang bersifat <i>white noise</i>
α	: Taraf signifikansi pengujian
B	: <i>Backshift</i> operator
β_1	: Koefisien variabel <i>dummy trend</i>
d	: Orde <i>differencing</i> non-musiman
D	: Orde <i>differencing</i> musiman
δ_j	: Koefisien variabel <i>dummy</i> variasi kalender minggu ke- j
ϕ_p	: Parameter <i>autoregressive</i> orde p non-musiman
Φ_P	: Parameter <i>autoregressive</i> orde P musiman
θ_q	: Parameter <i>moving average</i> orde q non-musiman
Θ_Q	: Parameter <i>moving average</i> orde Q musiman
J	: Fungsi likelihood
N	: Banyaknya data pengamatan
n	: Banyaknya data <i>in-sample</i>
m^*	: Banyaknya data <i>out-sample</i>
$M_{i,t}$: <i>Dummy</i> musiman bulan ke- i periode ke- t
p	: Orde <i>autoregressive</i> non-musiman
P	: Orde <i>autoregressive</i> musiman
q	: Orde <i>moving average</i> non-musiman
Q	: Orde <i>moving average</i> musiman
s	: Orde musiman
t	: Periode atau waktu, $t=1,2,...,N$
T_t^*	: Variabel <i>dummy trend</i> periode ke- t
λ	: Parameter transformasi Box-cox
$V_{j,t}$: Variabel <i>dummy</i> variasi kalender minggu ke- j periode ke- t
W_t	: Data <i>differencing</i> periode ke- t
γ_i	: Koefisien variabel <i>dummy</i> musiman bulan ke- i
Y_t	: Data <i>time series</i> periode ke- t

\hat{Y}_t : Data *time series* hasil ramalan periode ke- t

Singular Spectrum Analysis

F : Deret waktu
 F_N : Deret waktu dengan panjang N
 f_i : Elemen ke- i dari deret waktu
 K : Jumlah L *lagged vectors* dari F_N
 L : Parameter *window length*
 N_t^* : Data *time series* kelompok *Noise* periode ke- t
 m : Banyaknya deret yang direkonstruksi
 O_i : Vektor faktor ke- i dari SVD matriks
 S_t : Data *time series* kelompok *Seasonality* periode ke- t
 T_t : Data *time series* kelompok *Trend* periode ke- t
 λ_i^* : Nilai eigen ke- i
 U_i : Vektor eigen ke- i dari matriks SVD
 O_i : Vektor faktor ke- i dari matriks SVD
 X_i : L *lagged vectors* ke- i dari deret waktu
 \mathbf{X} : Matriks lintasan
 \mathbf{X}^T : *Transpose* dari matriks lintasan

Adaptive Neuro Fuzzy Inference System

A_{r^*} : Fungsi keanggotaan *input* 1 ke- r^*
 B_{r^*} : Fungsi keanggotaan *input* 2 ke- r^*
 g : Aturan atau *rule*, $g=1,2,...,G$
 G : Banyaknya aturan atau *rule*
 $h_{g,u,t}$: Parameter konsekuen *input* ke- u pada aturan ke- g periode ke- t
 r^* : Indeks fungsi keanggotaan, $r^*=1,2,...,R$
 R : Banyaknya fungsi keanggotaan
 $w_{g,t}$: *Fire strength* aturan ke- g periode ke- t

- $\overline{w}_{g,t}$: *Normalized firing strength* aturan ke- g periode ke- t
 u : Indeks variabel *input*, $u = 1, 2, \dots, u^*$
 $u(x)$: derajat keanggotaan untuk variabel *input* x

(Halaman ini sengaja dikosongkan)

BAB I

PENDAHULUAN

1.1 Latar Belakang

Uang merupakan suatu benda yang memiliki nilai dan peran penting dalam kehidupan perekonomian manusia. Uang adalah sesuatu yang diterima secara umum sebagai alat pembayaran resmi dalam memenuhi kewajiban sistem moneter. Secara umum, uang mempunyai tiga tujuan yang berbeda bergantung pada penggunaannya. Tujuan pertama yaitu uang sebagai alat tukar untuk pembayaran di antara konsumen, badan usaha dan pemerintah. Tujuan kedua yaitu uang sebagai satuan dasar atau nilai yang dibayarkan untuk memperoleh barang dan jasa. Tujuan ketiga yaitu uang sebagai alat penyimpanan nilai. Uang dapat mengukur nilai ekonomis pendapatan di masa sekarang terhadap pengeluaran di masa yang akan datang.

Uang beredar merupakan kewajiban sistem moneter terhadap sektor swasta domestik. Sistem moneter terdiri dari Bank Sentral, Bank Umum, serta Bank Perkreditan Rakyat (BPR). Sektor swasta domestik pada uang beredar tidak termasuk pemerintah pusat dan penduduk. Komponen uang beredar terdiri atas uang kartal, uang giral, uang kuasi, dan surat berharga selain saham yang diterbitkan oleh sistem moneter (Bank Indonesia, 2017). Uang yang beredar di masyarakat umumnya adalah uang kartal. Di Indonesia, uang kartal yaitu uang kertas dan uang logam yang beredar di masyarakat dan dikeluarkan oleh Bank Indonesia sebagai otoritas moneter (Solikin & Suseno, 2002).

Bank Indonesia (BI) merupakan satu-satunya lembaga yang berwenang mengeluarkan, mengedarkan, mencabut, menarik dan memusnahkan uang Rupiah. Terkait dengan peran tersebut, BI senantiasa berupaya memenuhi kebutuhan uang kartal di masyarakat dalam kriteria yang ideal. Kriteria yang dimaksud meliputi nominal yang cukup, jenis pecahan yang sesuai, tepat waktu, dan kondisi yang layak edar. Pengelolaan pengedaran

uang dilakukan BI mulai dari pengeluaran, pagedaran, pencabutan dan penarikan sampai dengan pemusnahan uang.

Sebelum mengeluarkan uang rupiah, BI melakukan perencanaan agar uang rupiah memiliki kualitas yang baik. Jika kualitas uang rupiah baik, maka kepercayaan masyarakat terhadap BI tetap terjaga. Perencanaan tersebut di antaranya perencanaan pengeluaran emisi baru yang mempertimbangkan tingkat pemalsuan, unsur intrinsik dan masa edar uang. Selain itu, dilakukan perencanaan terhadap jumlah dan komposisi pecahan uang dalam satu tahun ke depan. Selanjutnya BI melakukan percetakan uang baik untuk uang emisi baru ataupun percetakan uang emisi lama. BI mengedarkan uang rupiah yang dikeluarkan ke seluruh wilayah melalui Kantor Bank Indonesia. Setiap kantor BI membutuhkan uang rupiah yang berbeda-beda. Banyaknya uang rupiah yang dibutuhkan tergantung pada keperluan pembayaran, jumlah persediaan, penggantian dan penukaran uang dalam jangka waktu tertentu (Bank Indonesia, 2017).

Indikator jumlah uang yang beredar dapat dilihat melalui *inflow* dan *outflow*. *Inflow* uang kartal merupakan aliran informasi mengenai uang kertas dan kerta yang masuk dari masyarakat dan perbankan ke Bank Indonesia. Informasi tersebut terdiri dari penukaran masuk loket Bank Indonesia, setoran bank dan non bank, kas keliling, dan transaksi masuk kas titipan. *Outflow* uang kartal merupakan aliran informasi mengenai uang kertas dan logam yang keluar dari Bank Indonesia kepada masyarakat dan perbankan. Salah satu variabel yang memiliki pengaruh signifikan terhadap tingkat inflasi di Indonesia yaitu jumlah uang beredar. Jumlah uang beredar dalam jangka pendek maupun jangka panjang memiliki hubungan positif terhadap tingkat inflasi di Indonesia. Hal tersebut dinyatakan dalam penelitian yang dilakukan oleh Sutawijaya dan Zulfahmi (2014). Inflasi merupakan proses kenaikan harga barang secara terus menerus (Nopirin, 1990). Semakin tinggi jumlah uang beredar akan semakin meningkatkan inflasi sedangkan semakin rendah jumlah uang beredar semakin menurunkan inflasi. Penurunan inflasi yang

signifikan dapat mengindikasikan terjadinya deflasi yaitu penurunan harga barang secara terus menerus. Adanya inflasi dan deflasi menyebabkan ketidakseimbangan neraca perekonomian. Dalam hal mencegah terjadinya inflasi maupun deflasi, perlu dilakukan peramalan terhadap jumlah uang beredar. Peramalan *inflow* dan *outflow* uang kartal perlu dilakukan agar terjadi keseimbangan antara jumlah uang kartal yang beredar dengan kebutuhan masyarakat. Peramalan yang tepat dijadikan informasi yang dapat dipertimbangkan oleh Bank Indonesia untuk perencanaan pengeluaran, peredaran maupun penarikan uang kartal jangka pendek.

Penelitian-penelitian yang pernah dilakukan terkait dengan peramalan *inflow* dan *outflow* uang kartal antara lain yaitu penelitian yang dilakukan oleh Guo (2015). Guo menggunakan metode peramalan deret waktu klasik yaitu peramalan satu titik menggunakan ARMA dan hasil yang diperoleh yaitu model ARMA memiliki banyak kekurangan dan hanya bisa memprediksi *trend* saja. Peramalan peredaran uang juga dilakukan oleh Ikoku (2014) di Nigeria dengan menggunakan metode AR(1), ARIMA, *Seasonal ARIMA* (SARIMA), *Vector Autoregressive* (VAR), dan *Vector Error Correction* (VEC). Di Indonesia, Safitri, Setiawan, dan Ahmad (2016) menggunakan metode *generalize space time autoregressive* (GSTAR) untuk meramalkan *outflow* uang pecahan di Jawa Timur. Hasil yang didapatkan yaitu model *time series regression* dengan efek variasi kalender berupa hari raya Idul Fitri lebih baik dalam meramalkan *outflow* uang pecahan. Susanti dan Suhartono (2016) menggunakan model hibrida *exponential smoothing* pendekatan *state space* dengan variasi kalender untuk meramalkan *inflow* dan *outflow* uang kartal di Jawa Timur. Wulansari, Setiawan dan Suhartono (2017) menggunakan metode ARIMAX, *hybrid ARIMAX-ANN*, dan VARI-X untuk meramalkan *outflow* tiap pecahan uang kartal di Bank Indonesia regional Surabaya. Berdasarkan penelitian-penelitian tersebut penambahan efek variasi kalender hari raya Idul Fitri terbukti memberikan hasil

peramalan yang lebih baik sehingga pada penelitian ini digunakan metode ARIMAX sebagai metode pembandingan.

Suatu pola data yang didekomposisi menjadi sub pola terpisah dapat meningkatkan ketepatan hasil peramalan dengan lebih baik (Makridakis, Wheelwright, & Hyndman, 1998). Salah satu pengembangan dari metode dekomposisi klasik adalah metode *singular spectrum analysis* (SSA). SSA merupakan sebuah teknik analisis deret waktu dan peramalan. SSA mengkombinasikan elemen klasik analisis deret waktu, statistika multivariat, geometri multivariat, sistem dinamik dan pemrosesan sinyal. SSA memiliki tujuan untuk mendekomposisi sebuah rangkaian data menjadi jumlahan komponen-komponen kecil yang dapat diinterpretasikan. Terdapat dua tahapan yang saling melengkapi dalam algoritma SSA yaitu tahap dekomposisi dan tahap rekonstruksi. Pada tahap dekomposisi, dua langkah utama yang harus dilakukan untuk memperoleh *eigentriple*, yaitu *embedding* dan *singular value decomposition*. Pada tahap rekonstruksi, dua langkah yang harus dilakukan untuk memperoleh deret yang direkonstruksi, yaitu pengelompokan dan *diagonal averaging*. Beberapa penelitian yang telah menggunakan SSA diantaranya yaitu penelitian yang dilakukan oleh Hassani, Webster, Silva, dan Heravi (2015). Hassani dkk menggunakan SSA untuk peramalan kedatangan wisatawan Amerika Serikat dengan membandingkan metode peramalan ARIMA, *exponential smoothing*, dan *neural network*. Kesimpulan penelitian yang diperoleh yaitu hasil ramalan dengan metode SSA lebih baik dibandingkan dengan metode-metode lainnya.

Di Indonesia, peramalan dengan metode SSA dilakukan oleh Ete, Suharsono, dan Suhartono (2017) terhadap jumlah kedatangan wisatawan mancanegara menurut pintu masuk. Kesimpulan yang didapatkan yaitu metode SSA memberikan tingkat akurasi ramalan yang tinggi jika dibandingkan dengan metode ARIMA ketika data yang digunakan mengandung komponen musiman yang kompleks. Perkembangan metode SSA saat ini dikombinasikan dengan berbagai metode peramalan yang

lain diantaranya model *autoregressive* (AR) dan ARIMA. Metode peramalan hibrida SSA-AR dilakukan oleh Li, Cui, dan Guo (2014) pada *short term power load* di pasar listrik PJM Mid-Atlantic. Hasil yang diperoleh yaitu metode hibrida SSA-AR menunjukkan performa yang lebih baik jika dibandingkan dengan metode peramalan AR, *SSA-based linear recurrent method* atau disebut *linear recurrent formulae* (SSA-LRF), dan BPNN (*backpropagation neural network*). Model hibrida SSA-ARIMA juga menunjukkan performa yang baik pada peramalan aliran hidrologi tahunan di China dibandingkan ARIMA dan SSA-LRF (Zhang, Wang, He, Peng, & Ren, 2011).

Berdasarkan uraian sebelumnya tentang SSA, dapat dilihat bahwa SSA memiliki keunggulan dalam bidang peramalan. Oleh karena itu, pada penelitian ini digunakan metode SSA untuk meramalkan *inflow* dan *outflow* uang kartal di Indonesia. Metode SSA digabungkan dengan salah satu metode peramalan modern yaitu *adaptive neuro fuzzy inference system* (ANFIS). Model gabungan atau hibrida digunakan agar memberikan hasil peramalan yang lebih akurat. ANFIS merupakan metode yang penting dan layak digunakan dalam peramalan jika data masa lalu memiliki pola *non-linier* (Zounermant-Kermani & Teshnehlab, 2008). Saat ini data *inflow* dan *outflow* uang kartal di Indonesia diindikasikan memiliki pola data *non-linier*, sehingga penggunaan ANFIS diharapkan dapat menangkap pola *non-linier* dari data tersebut. Keuntungan dari penggunaan model *non-linier* sendiri adalah tidak memerlukan asumsi-asumsi tertentu.

ANFIS adalah sebuah kombinasi dari dua metode komputasi yaitu *artificial neural network* (ANN) atau jaringan syaraf tiruan (JST) dan logika *fuzzy* (Suparta & Alhasa, 2016). Metode ANFIS lebih unggul jika dibandingkan dengan metode *neural network autoregressive model with exogenous inputs* (NN-ARX) dan model empiris untuk radiasi matahari (Piri & Kisi, 2015). Nguyen, Li, dan Nguyen (2017) menggunakan ANFIS untuk meramalkan kekeringan, nilai kuantitatif indeks kekeringan, indeks pengendapan standar (SPI) dan indeks

evapotranspirasi standar (SPEI) di Vietnam. Azalia, Susilaningrum, dan Suhartono (2016) menerapkan metode ANFIS untuk meramalkan kebutuhan energi listrik bulanan di Gresik, Jawa Timur.

Model hibrida yang telah dikembangkan dan berkaitan dengan hibrida SSA-ANFIS diantaranya yaitu model hibrida *local linear neuro fuzzy* (LLNF) dan *optimized singular spectrum analysis* (OSSA) (Abdollahzade, Miranian, Hassani, & Iranmanesh, 2015). Perbandingan hasil yang diperoleh dengan beberapa metode, model hibrida OSSA-LLNF menunjukkan keunggulan dan kinerja yang baik. Xiao dkk. (2014) mengusulkan pendekatan hibrida yang menggabungkan *singular spectrum analysis* (SSA), *adaptive neuro fuzzy inference system* (ANFIS) dan *improved particle swarm optimization* (IPSO), untuk prediksi lalu lintas penumpang jangka pendek. Dalam penelitian tersebut SSA digunakan untuk mengidentifikasi dan mengekstrak tren dan musiman permintaan transportasi udara dan teknologi intelijen buatan, termasuk ANFIS dan IPSO, digunakan untuk mengatasi ketidakaturan dan ketidakstabilan permintaan. Zhang, Song, Liu, dan Liu (2016) mengusulkan model hibrida IFASF (*interval forecast-ANFIS-SSA-firefly alogorithm*) untuk meramalkan rata-rata kekuatan angin harian. Hasil perbandingan model hibrida IFASF menunjukkan bahwa model yang dikembangkan lebih efektif dari metode-metode lainnya.

Terdapat dua kajian yang digunakan pada penelitian ini yaitu kajian simulasi dan kajian terapan. Kajian simulasi dilakukan untuk memahami pola data dari hasil dekomposisi metode SSA. Selain itu, kajian simulasi dilakukan untuk mengetahui cara kerja metode SSA pada data dengan variasi kalender. Hasil dekomposisi SSA diramalkan dengan metode ANFIS baik secara individu maupun agregat. Adanya kajian simulasi juga digunakan untuk menentukan peforma yang lebih baik antara SSA-ANFIS agregat dan SSA-ANFIS individu. Jenis SSA-ANFIS terbaik pada kajian simulasi akan digunakan di kajian terapan. Data yang digunakan dalam kajian terapan yaitu

data *inflow* dan *outflow* uang kartal di Indonesia tahun 2003 sampai dengan tahun 2016. Diharapkan penggunaan model hibrida SSA-ANFIS ini dapat memberikan hasil peramalan *inflow* dan *outflow* yang lebih akurat.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, berikut permasalahan yang akan dibahas dalam penelitian ini.

1. Bagaimana hasil kajian simulasi pada metode *singular spectrum analysis* dan *adaptive neuro fuzzy inference system* (SSA-ANFIS)?
2. Bagaimana hasil peramalan menggunakan model ARIMAX pada data *inflow* dan *outflow* uang kartal di Indonesia?
3. Bagaimana hasil peramalan menggunakan model hibrida SSA-ANFIS pada data *inflow* dan *outflow* uang kartal di Indonesia?
4. Bagaimana perbandingan akurasi peramalan menggunakan model ARIMAX dan hibrida SSA-ANFIS beserta kekuatan peramalannya?
5. Bagaimana hasil peramalan *inflow* dan *outflow* uang kartal di Indonesia menggunakan model terbaik?

1.3 Tujuan

Berikut diuraikan tujuan penelitian yang disesuaikan dengan rumusan masalah penelitian.

1. Mendapatkan hasil dari kajian simulasi pada metode SSA-ANFIS.
2. Mendapatkan model ARIMAX untuk meramalkan *inflow* dan *outflow* uang kartal di Indonesia.
3. Mendapatkan model hibrida SSA-ANFIS untuk meramalkan *inflow* dan *outflow* uang kartal di Indonesia.
4. Mendapatkan perbandingan akurasi peramalan data *inflow* dan *outflow* di Indonesia menggunakan ARIMAX, ANFIS dan hibrida SSA-ANFIS beserta kekuatan ramalan model terbaik.
5. Mendapatkan hasil peramalan *inflow* dan *outflow* uang kartal di Indonesia menggunakan model terbaik.

1.4 Manfaat

Penelitian ini diharapkan dapat memberikan beberapa manfaat bagi berbagai pihak, diantaranya yaitu:

1. Memberikan informasi yang dapat digunakan pihak Bank Indonesia dalam melakukan perencanaan, pengedaran, penerbitan dan pemusnahan uang rupiah,
2. Memberikan tambahan keilmuan statistika terkait model hibrida SSA-ANFIS.

1.5 Batasan Masalah

Batasan masalah yang digunakan dalam penelitian ini adalah data penelitian yang digunakan merupakan data pecahan *inflow* dan *outflow* nasional tahun 2003 sampai dengan tahun 2016. Pemodelan *time series* yang digunakan untuk meramalkan *inflow* dan *outflow* uang kartal tersebut adalah model ARIMAX dan hibrida SSA-ANFIS. Variabel *dummy* yang digunakan yaitu *dummy* untuk musiman bulan, *trend*, dan efek hari raya Idul Fitri.

BAB II

TINJAUAN PUSTAKA

2.1 Analisis Deret Waktu

Deret waktu adalah sebuah urutan pengamatan yang teratur. Meskipun urutan pengamatan biasanya melalui waktu, dalam beberapa interval waktu yang sama, urutan pengamatan juga dapat dilakukan melalui dimensi lain, misalnya ruang. Deret waktu dapat terjadi dalam berbagai bidang. Di bidang pertanian, pengamatan terhadap produksi dan harga tanaman tahunan merupakan suatu deret waktu. Pengamatan terhadap harga saham harian, suku bunga, indeks harga dan pendapatan tahunan dalam bidang bisnis dan ekonomi juga termasuk deret waktu. Di bidang teknik, kejadian deret waktu misalnya pengamatan terhadap suara, sinyal listrik dan juga tegangan. Kegiatan merekam turbulensi, seperti gelombang laut dan kebisingan bumi merupakan kejadian deret waktu dalam bidang geometri. Contoh lain yaitu pengukuran *electroencephalogram* (EEG) dan *electrocardiogram* (EKG) dalam bidang medis. Pengamatan terhadap kecepatan angin per jam, suhu harian, dan curah hujan tahunan merupakan deret waktu dalam bidang meteorologi. Pembelajaran tentang tingkat kelahiran tahunan, tingkat kematian, tingkat kecelakaan, dan berbagai tingkat kejahatan dalam bidang sains juga merupakan deret waktu. Penelitian serta bidang-bidang dimana deret waktu diamati tidak ada habisnya. Ada berbagai tujuan mempelajari deret waktu. Tujuan tersebut mencakup pemahaman dan deskripsi mekanisme pembangkit, peramalan nilai masa depan, dan pengendalian sistem yang optimal. Sifat intrinsik deret waktu adalah pengamatan yang berkorelasi dan adanya urutan pengamatan (Wei, 2006).

2.2 *Seasonal Autoregressive Integrated Moving Average* (SARIMA)

Secara umum persamaan dari model *seasonal* ARIMA yaitu:

$$\Phi_P(B^s)\phi_p(B)(1-B)^d(1-B^s)^D\dot{Y}_t = \theta_q(B)\Theta_Q(B^s)a_t, \quad (2.1)$$

dengan:

$$\begin{aligned} \phi_p(B) &= 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p, \text{ } p \text{ merupakan orde AR non musiman,} \\ \Phi_P(B^s) &= 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps}, \text{ } P \text{ merupakan orde AR musiman } s, \\ \theta_q(B) &= 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q, \text{ } q \text{ merupakan orde MA non musiman,} \\ \Theta_Q(B^s) &= 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs}, \text{ } Q \text{ merupakan orde MA musiman } s, \\ (1-B)^d &= \text{operator } \textit{differencing} \text{ orde } d, \\ (1-B^s)^D &= \text{operator } \textit{differencing} \text{ musiman } s \text{ orde } D, \\ a_t &= \text{error pada waktu ke-} t. \end{aligned}$$

Pembentukan model ARIMA atau *seasonal* ARIMA menggunakan prosedur Box-Jenkins. Prosedur Box-Jenkins terdiri dari tahap identifikasi, estimasi parameter, cek diagnosa dan tahap peramalan.

2.2.1 Identifikasi

Langkah awal dalam prosedur Box-Jenkins adalah identifikasi orde dari model ARIMA. Data yang digunakan dalam pemodelan dengan ARIMA harus memenuhi asumsi stasioner dalam *mean* dan *varians*. Ketidakstasioneran data dalam *varians* dapat diatasi dengan tranformasi Box-Cox menggunakan persamaan:

$$Y_t^{(\lambda)} = \begin{cases} \frac{Y_t^\lambda - 1}{\lambda}, \lambda \neq 0, \\ \log(Y_t), \lambda = 0, \end{cases} \quad (2.2)$$

dengan λ merupakan parameter pada transformasi Box-Cox (Box & Cox, 1964).

Pengujian stasioneritas dalam *mean* dapat dilakukan menggunakan uji Dickey-Fuller. Agar data menjadi stasioner dalam *mean* maka dilakukan *differencing* menggunakan persamaan:

$$W_t = (1 - B)^d Y_t. \quad (2.3)$$

Selanjutnya menentukan orde ARIMA berdasarkan plot *autocorrelation function* (ACF) dan *partial autocorrelation function* (PACF) dari data yang sudah stasioner dalam *mean* dan *varians* (Wei, 2006).

Tabel 2.1 Identifikasi Orde Model ARMA

Model	Plot ACF	Plot PACF
Non Musiman		
AR(p)	<i>dies down</i> (turun cepat)	<i>Cut off</i> setelah lag ke- p
MA(q)	<i>Cut off</i> setelah lag ke- q	<i>dies down</i> (turun cepat)
ARMA(p, q)	<i>dies down</i>	<i>dies down</i>
Musiman dengan periode s		
AR(P)	<i>dies down</i> (turun cepat)	<i>Cut off</i> setelah lag ke- Ps
MA(Q)	<i>Cut off</i> setelah lag ke- Qs	<i>dies down</i> (turun cepat)
ARMA(P, Q)	<i>dies down</i>	<i>dies down</i>

2.2.2 Estimasi Parameter

Estimasi parameter dilakukan untuk memperoleh nilai parameter pada model ARIMA. Salah satu metode estimasi parameter yang dapat digunakan yaitu metode *Maximum Likelihood Estimation* (MLE). Ada dua tahap pada MLE yaitu menentukan fungsi *likelihood* dan nilai estimasi yang dapat memaksimumkan fungsi *likelihood* (Hamilton, 1994). Model *autoregressive* orde p atau AR(p) dapat dituliskan sebagai:

$$\dot{Y}_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t, \quad (2.4)$$

dengan $a_t \sim \text{iid}N(0, \sigma^2)$. Jika diberikan pengamatan Y_1, Y_2, \dots, Y_N , maka fungsi *likelihood* J merupakan *joint probability density*

dari data yang diamati. J merupakan fungsi dari ϕ dan σ^2 dengan syarat Y_1, Y_2, \dots, Y_N untuk model $AR(p)$. Dengan demikian, fungsi likelihood J dapat dituliskan sebagai:

$$\begin{aligned} J(a_1, a_2, \dots, a_N) &= \prod_{t=1}^N \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(a_t)^2} \\ &= \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^N e^{-\frac{1}{2\sigma^2} \sum_{t=1}^N a_t^2}. \end{aligned} \quad (2.5)$$

Fungsi \ln likelihood diberikan dalam persamaan:

$$\ln J(a_1, a_2, \dots, a_N) = \ln \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^N + \left(-\frac{1}{2\sigma^2} \sum_{t=1}^N a_t^2 \right). \quad (2.6)$$

Memaksimumkan fungsi likelihood sama saja dengan memaksimumkan fungsi \ln likelihood. Memaksimumkan fungsi dilakukan dengan cara menurunkan fungsi tersebut terhadap parameter yang akan diestimasi. Fungsi turunan dari \ln likelihood terhadap parameter $AR(p)$ yaitu:

$$\frac{\partial \ln J(a_1, a_2, \dots, a_N)}{\partial \phi} = 0. \quad (2.7)$$

Diketahui nilai a_t pada model $AR(1)$ adalah $a_t = \dot{Y}_t - \phi_1 Y_{t-1}$, sehingga estimasi parameter ϕ_1 didapatkan dari perhitungan:

$$\begin{aligned} \frac{\partial \left(\ln \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^N + \left(-\frac{1}{2\sigma^2} \sum_{t=2}^N (\dot{Y}_t - \phi_1 Y_{t-1})^2 \right) \right)}{\partial \phi_1} &= 0 \\ 0 - \frac{1}{2\sigma^2} 2 \sum_{t=2}^N (\dot{Y}_t - \phi_1 Y_{t-1})(-Y_{t-1}) &= 0 \\ -\frac{1}{\sigma^2} \sum_{t=2}^N (\dot{Y}_t - \phi_1 Y_{t-1})(-Y_{t-1}) &= 0 \\ \sum_{t=2}^N (-\dot{Y}_t Y_{t-1} + \phi_1 Y_{t-1}^2) &= 0 \end{aligned}$$

$$\begin{aligned}
& -\sum_{t=2}^N \dot{Y}_t Y_{t-1} + \phi_1 \sum_{t=2}^N Y_{t-1}^2 = 0 \\
& \hat{\phi}_1 = \frac{\sum_{t=2}^N \dot{Y}_t Y_{t-1}}{\sum_{t=2}^N Y_{t-1}^2} \quad (2.8)
\end{aligned}$$

Nilai a_t pada model $AR(p)$ yaitu $a_t = \dot{Y}_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p}$. Estimasi parameter ϕ_1 dapat ditunjukkan dengan persamaan:

$$\begin{aligned}
& \frac{\partial \left(\ln \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^N + \left(-\frac{1}{2\sigma^2} \sum_{t=1}^N (\dot{Y}_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p})^2 \right) \right)}{\partial \phi_1} = 0 \\
& 0 - \frac{1}{2\sigma^2} \left(2 \sum_{t=p+1}^N (\dot{Y}_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p}) (-Y_{t-1}) \right) = 0 \\
& - \frac{1}{\sigma^2} \sum_{t=p+1}^N (\dot{Y}_t - \phi_1 Y_{t-1} - \phi_2 Y_{t-2} - \dots - \phi_p Y_{t-p}) (-Y_{t-1}) = 0 \\
& \sum_{t=p+1}^N (-\dot{Y}_t Y_{t-1} + \phi_1 (Y_{t-1})^2 + \phi_2 Y_{t-1} Y_{t-2} + \dots + \phi_p Y_{t-1} Y_{t-p}) = 0 \\
& \sum_{t=p+1}^N (\dot{Y}_t Y_{t-1}) = \left(\sum_{t=p+1}^N (Y_{t-1})^2 \right) \phi_1 + \left(\sum_{t=p+1}^N (Y_{t-1} Y_{t-2}) \right) \phi_2 + \dots + \left(\sum_{t=p+1}^N (Y_{t-1} Y_{t-p}) \right) \phi_p. \quad (2.9)
\end{aligned}$$

Jika kedua sisi dibagi dengan $\sum_{t=p+1}^N (Y_t)^2$, maka diperoleh persamaan

Yule-Walker (Cryer & Chan, 2008):

$$\begin{aligned}
& \frac{\sum_{t=p+1}^N (\dot{Y}_t Y_{t-1})}{\sum_{t=p+1}^N (Y_t)^2} = \frac{\left(\sum_{t=p+1}^N (Y_{t-1})^2 \right)}{\sum_{t=p+1}^N (Y_t)^2} \phi_1 + \frac{\left(\sum_{t=p+1}^N (Y_{t-1} Y_{t-2}) \right)}{\sum_{t=p+1}^N (Y_t)^2} \phi_2 + \dots + \frac{\left(\sum_{t=p+1}^N (Y_{t-1} Y_{t-p}) \right)}{\sum_{t=p+1}^N (Y_t)^2} \phi_p. \\
& r_1 = \phi_1 + r_1 \phi_2 + r_2 \phi_3 + \dots + r_{p-1} \phi_p. \quad (2.10)
\end{aligned}$$

Pembentukan persamaan (2.10) juga diterapkan pada parameter $\phi_2, \phi_3, \dots, \phi_p$ sehingga didapatkan:

$$\begin{aligned} r_1 &= \phi_1 + r_1\phi_2 + r_2\phi_3 + \dots + r_{p-1}\phi_p \\ r_2 &= r_1\phi_1 + \phi_2 + r_2\phi_3 + \dots + r_{p-2}\phi_p \\ &\vdots \\ r_p &= r_{p-1}\phi_1 + r_{p-2}\phi_2 + r_{p-3}\phi_3 + \dots + \phi_p. \end{aligned} \quad (2.11)$$

Nilai $\phi_1, \phi_2, \phi_3, \dots, \phi_p$ dapat ditentukan sebagai berikut:

$$\begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix} = \begin{bmatrix} 1 & r_1 & r_2 & \cdots & r_{p-1} \\ r_1 & 1 & r_3 & \cdots & r_{p-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_{p-1} & r_{p-2} & r_{p-3} & \cdots & 1 \end{bmatrix}^{-1} \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_p \end{bmatrix}. \quad (2.12)$$

Setelah mendapatkan estimasi model AR, selanjutnya pengujian signifikansi parameter model AR dengan hipotesis:

$H_0: \phi_c = 0$,

$H_1: \phi_c \neq 0$, dengan $C = 1, 2, \dots, p$.

Statistik uji yang digunakan yaitu:

$$t_{\text{hitung}} = \frac{\hat{\phi}_c}{SE(\hat{\phi}_c)}, \quad (2.13)$$

dengan $SE(\hat{\phi}_c)$ adalah standar *error* parameter model AR. H_0 ditolak apabila nilai statistik uji $|t_{\text{hitung}}| > t_{\alpha/2, (N-N_p)}$, dengan N banyaknya pengamatan dan N_p merupakan banyaknya parameter yang diestimasi.

2.2.3 Cek Diagnosa

Pada tahap ini dilakukan uji asumsi *error* yang independen (*white noise*) dan distribusi normal. *Ljung-box test* dapat

digunakan untuk uji asumsi *white noise* dan pengujiannya adalah sebagai berikut:

H_0 : $\rho_1 = \rho_2 = \dots = \rho_H = 0$ (*error* independen),

H_1 : minimal ada satu $\rho_{h^*} \neq 0$ dengan $h^* = 1, 2, \dots, H$ (*error* tidak independen).

Statistik uji yang digunakan adalah:

$$Q^* = N(N+2) \sum_{h=1}^H \frac{\hat{\rho}_{h^*}^2}{N-h^*} \quad (2.14)$$

Tolak H_0 jika $Q^* > \chi_{\alpha, H-p-q}^2$, dimana $\hat{\rho}_{h^*}$ adalah autokorelasi dari *error* ke- h^* , p merupakan banyaknya parameter AR, q merupakan banyaknya parameter MA, N adalah banyaknya pengamatan dan α merupakan taraf signifikansi yang digunakan.

Berikutnya, uji Kolmogorov-Smirnov (KS) dapat dilakukan untuk pengujian distribusi normal pada *error*. Hipotesis yang digunakan yaitu:

H_0 : $F^*(a_t) = F_0^*(a_t)$ (*error* mengikuti distribusi normal),

H_1 : $F^*(a_t) \neq F_0^*(a_t)$ (*error* tidak mengikuti distribusi normal).

Statistik uji KS yaitu:

$$D^* = \text{Sup} | F^*(a_t) - F_0^*(a_t) |, \quad (2.15)$$

dengan:

$F^*(a_t)$: fungsi distribusi frekuensi kumulatif dari *error*

$F_0^*(a_t)$: fungsi distribusi frekuensi kumulatif distribusi normal.

Sup : nilai maksimum

Tolak H_0 jika $D^* > D_{N, \alpha}^{**}$ dengan D^{**} adalah nilai kritis uji KS, N adalah banyak pengamatan, dan α merupakan taraf signifikansi yang digunakan.

2.2.4 Peramalan

Prosedur Box-Jenkins yang terakhir yaitu melakukan peramalan pada data yang telah melewati tiga tahap sebelumnya.

Peramalan dilakukan untuk menghitung nilai ramalan l tahap ke depan. Ada dua macam peramalan yaitu peramalan titik dan peramalan interval. Peramalan titik untuk l tahap ke depan dapat dilakukan dengan:

$$\hat{Y}_N(l) = E(Y_{N+l} | Y_N, Y_{N-1}, \dots, Y_1), \quad (2.16)$$

dengan $\hat{Y}_N(l)$ adalah ramalan titik dari Y_{N+l} untuk periode l ke depan. Ramalan *error* l tahap ke depan yaitu:

$$e_N(l) = Y_{N+l} - \hat{Y}_N(l) = \sum_{j^*=0}^{l-1} \psi_{j^*}^2 a_{N+l-j^*}. \quad (2.17)$$

Nilai $E(e_N(l) | Y_l, t \leq N)$ adalah 0 sehingga varians dari *error* ramalan l tahap ke depan adalah:

$$\text{var}(e_N(l)) = \sigma_a^2 \sum_{j^*=0}^{l-1} \psi_{j^*}^2. \quad (2.18)$$

Interval peramalan $(1-\alpha)$ 100% pada proses yang normal yaitu:

$$\hat{Y}_N(l) \pm Z_{\alpha/2}^* \left[1 + \sum_{j^*=1}^{l-1} \psi_{j^*}^2 \right]^{1/2} \sigma_a, \quad (2.19)$$

dengan $Z_{\alpha/2}^*$ merupakan distribusi normal standar dari $P(z > Z_{\alpha/2}^*) = \alpha / 2$ (Wei, 2006).

2.3 Autoregressive Integrated Moving Average with Exogenous Variable (ARIMAX)

Model ARIMAX merupakan model ARIMA dengan variabel tambahan yang disebut sebagai variabel eksogen. Variabel eksogen tersebut antara lain berupa variabel deret waktu tertentu atau variabel *dummy* misalnya variasi kalender. Variasi kalender dapat diakibatkan adanya variasi hari kerja dan hari

besar suatu agama/kebudayaan tertentu (Lee, Suhartono, & Hamzah, 2010). Model umum ARIMAX dapat ditunjukkan oleh:

$$Y_t = \beta_0 + \beta_1 V_{1,t}^* + \beta_2 V_{2,t}^* + \dots + \beta_{\tilde{K}} V_{\tilde{K},t}^* + E_t, \quad (2.20)$$

dan
$$E_t = \frac{\theta_q(B)}{\phi_p(B)} a_t, \quad (2.21)$$

dengan:

t : 1,2,...,N

$V_{\tilde{k},t}^*$: variabel *dummy* ke- \tilde{k} periode ke- t , $\tilde{k} = 1,2,\dots,\tilde{K}$

$\phi_p(B)$: $(1 - \phi_1 B - \dots - \phi_p B^p)$

$\theta_q(B)$: $(1 - \theta_1 B - \dots - \theta_q B^q)$

E_t : *error* pada periode ke- t

a_t : *error* pada periode ke- t keseluruhan dari proses ARIMAX.

Variabel eksogen yang digunakan dalam penelitian ini adalah variabel *dummy* musiman bulan, *trend*, dan efek variasi kalender hari raya Idul Fitri. Pada penelitian ini diasumsikan bahwa efek variasi kalender hari raya Idul Fitri dapat direpresentasikan oleh minggu terjadinya hari raya Idul Fitri, sehingga model matematis ARIMAX yang terbentuk yaitu:

$$Y_t = \beta_1 T_t^* + \gamma_1 M_{1,t} + \gamma_2 M_{2,t} + \dots + \gamma_{12} M_{12,t} + \delta_1 V_{1,t} + \delta_2 V_{1,t} + \delta_3 V_{1,t} + \delta_4 V_{4,t} + \frac{\theta_q(B)}{\phi_p(B)} a_t, \quad (2.22)$$

dengan:

T_t^* : variabel *dummy trend* periode ke- t

$M_{i,t}$: variabel *dummy* musiman bulan ke- i pada periode ke- t ,
 $i = 1,2,\dots,12$

$V_{j,t}$: variabel *dummy* variasi kalender hari raya Idul Fitri minggu ke- j periode ke- t , $j = 1,2,3,4$.

2.4 Uji Dickey-Fuller

Dickey dan Fuller telah mengembangkan sebuah pengujian, yang dikenal dengan *Augmented Dickey-Fuller (ADF) test* dalam menguji stasioneritas data. Uji ADF mengestimasi model regresi berikut:

$$\Delta Y_t = \beta_0 + \beta_1 t + \delta^* Y_{t-1} + \sum_{s^*=1}^{s^*} \omega \Delta Y_{t-s^*} + a_t, \quad (2.23)$$

dengan a_t adalah *error* yang *white noise*, $\Delta Y_{t-1} = (Y_{t-1} - Y_{t-2})$, $\Delta Y_{t-2} = (Y_{t-2} - Y_{t-3})$, dan seterusnya. Pada uji ADF dilakukan pengujian terhadap $\delta^* = 0$ yang dapat dijabarkan dalam hipotesis: $H_0 : \delta^* = 0$ (ada *unit root*, data tidak stasioner), $H_1 : \delta^* \neq 0$ (tidak ada *unit root* data stasioner).

Statistik uji yang digunakan yaitu:

$$\tau = \frac{\hat{\delta}^*}{SE(\hat{\delta}^*)}. \quad (2.24)$$

Didapatkan keputusan tolak H_0 jika nilai $|\tau|$ lebih dari nilai τ_{tabel} yaitu nilai kritis *Dickey-Fuller* (Gujarati, 2003).

Nilai τ statistik dapat dikonversikan ke dalam bentuk probabilitas yaitu *p-value* dengan cara menentukan nilai $P(\tau > \tau_{\text{tabel}}) = \alpha / 2$. Oleh karena itu, *p-value* juga dapat digunakan sebagai statistik uji ADF yang dalam pengujiannya dibandingkan dengan taraf signifikansi (α). Tolak H_0 jika *p-value* $< \alpha$ yang artinya data sudah stasioner.

2.5 Singular Spectrum Analysis (SSA)

Singular Spectrum Analysis (SSA) merupakan sebuah teknik analisis deret waktu dan peramalan. SSA mengkombinasikan elemen klasik analisis deret waktu, statistika multivariat, geometri multivariat, sistem dinamik dan pemrosesan sinyal. SSA memiliki tujuan untuk mendekomposisi sebuah rangkaian data menjadi jumlahan komponen-komponen kecil

yang dapat diinterpretasikan. Hal tersebut didasarkan pada dekomposisi nilai singular (SVD) dari matriks tertentu yang dibangun pada sebuah deret waktu. Terdapat dua tahapan yang saling melengkapi dalam algoritma SSA yaitu tahap dekomposisi dan tahap rekonstruksi (Golyandina & Zhigljavsky, 2013).

2.5.1 Dekomposisi

Perhatikan sebuah deret waktu bernilai riil $F = F_N = (x_1, \dots, x_N)$ dengan panjang N . Asumsikan $N > 2$ dan F bukan 0, sehingga ada paling tidak satu $x_i \neq 0$. Misalkan $L(1 < L < N)$ adalah bilangan bulat yang disebut *window length* dan $K = N - L + 1$. Pada tahap dekomposisi terdapat dua langkah analisis yaitu *embedding* dan *singular value decomposition* (SVD).

a. *Embedding*

Deret waktu asli pada tahapan *embedding* dipetakan dalam serangkaian *lagged vector* berukuran L dengan membentuk K *lagged vectors*.

$$X_i = (x_i, \dots, x_{i+L-1})^T, (1 \leq i \leq K)$$

berukuran L . Jika ukuran X_i ditekankan, maka X_i disebut sebagai L *lagged vectors*. Matriks lintasan \mathbf{X} yang dari serangkaian *lagged vectors* dapat dilihat pada persamaan 2.24.

$$\mathbf{X} = [X_1 : \dots : X_K] = (x_{ij})_{i,j=1}^{L,K} = \begin{bmatrix} x_1 & x_2 & x_3 & \cdots & x_K \\ x_2 & x_3 & x_4 & \cdots & x_{K+1} \\ x_3 & x_4 & x_5 & \cdots & x_{K+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_L & x_{L+1} & x_{L+2} & \cdots & x_N \end{bmatrix} \quad (2.25)$$

Lagged vectors X_i merupakan kolom matriks lintasan \mathbf{X} . Baris dan kolom dari matriks lintasan \mathbf{X} merupakan subderet dari deret asli. Elemen ke $-(i, j)$ dari matriks lintasan \mathbf{X} adalah $x_{ij} = x_{i+j-1}$.

Matriks lintasan \mathbf{X} memiliki elemen yang sama pada antidiagonal matriksnya sehingga matriks lintasan \mathbf{X} merupakan sebuah matriks Hankel. Persamaan 2.24 menetapkan bahwa terdapat korespondensi satu-satu antara matriks lintasan $L \times K$ dengan deret waktu.

b. *Singular Value Decomposition (SVD)*

Selanjutnya yaitu dekomposisi nilai singular dari matriks lintasan \mathbf{X} . Diberikan $\mathbf{A} = \mathbf{X}\mathbf{X}^T$ dengan $\lambda_1^*, \dots, \lambda_L^*$ merupakan nilai eigen matriks \mathbf{A} dimana $\lambda_1^* \geq \dots \geq \lambda_L^* \geq 0$ dan U_1, \dots, U_L merupakan vektor eigen yang bersesuaian dengan nilai eigen dari matriks \mathbf{A} . Diberikan $d^* = \text{rank } \mathbf{X} = \max\{i, \text{ sehingga } \lambda_i^* > 0\}$. Biasanya $d^* = L^*$ dimana $L^* = \min\{L, K\}$ dan $O_i = \mathbf{X}^T U_i / \sqrt{\lambda_i^*}$ ($i=1, \dots, d^*$). SVD dapat dituliskan menjadi sebuah persamaan yaitu:

$$\mathbf{X} = \mathbf{X}_1 + \dots + \mathbf{X}_{d^*}, \quad (2.26)$$

dengan $\mathbf{X}_i = \sqrt{\lambda_i^*} U_i O_i^T$. Matriks \mathbf{X}_i mempunyai rank 1 sehingga disebut matriks elemen. Gabungan $(\sqrt{\lambda_i^*}, U_i, O_i)$ disebut sebagai *eigentriple* ke- i dari SVD.

2.5.2 Rekonstruksi

Tahapan SSA yang kedua yaitu rekonstruksi. Dua hal penting yang dilakukan dalam rekonstruksi yaitu pengelompokan *eigentriple* dan *diagonal averaging*.

a. *Pengelompokan Eigentriple*

Setelah memperoleh ekspansi persamaan (2.26) maka prosedur pengelompokan ini akan melakukan partisi terhadap himpunan $(1, \dots, d^*)$ ke dalam m himpunan bagian yang saling lepas yaitu I_1, \dots, I_m . Misalkan $I = \{i_1, \dots, i_p\}$, maka matriks \mathbf{X}_I akan bersesuaian dengan kelompok I_1, \dots, I_m dan ekspansi (2.26) membentuk dekomposisi:

$$\mathbf{X} = \mathbf{X}_{I_1} + \dots + \mathbf{X}_{I_m}. \quad (2.27)$$

Pemilihan himpunan I_1, \dots, I_m disebut pengelompokan *eigentriple*. Jika $m = d^*$ dan $I_j = \{j\}$, $j = 1, 2, \dots, d^*$, maka pengelompokan yang bersesuaian disebut elementer. *Eigentriple* dikelompokkan ke dalam komponen *noise*, *trend* dan *seasonality*. *Trend* didefinisikan sebagai suatu komponen aditif dari deret yang tidak stasioner dan bervariasi dengan lambat selama keseluruhan periode waktu sedangkan *noise* merupakan deret aperiodik.

b. *Diagonal Averaging*

Setiap matriks \mathbf{X}_{ij} dari dekomposisi yang dikelompokkan oleh persamaan (2.27) diubah menjadi suatu deret baru dengan panjang N . Misalkan \mathbf{Y} adalah sebuah matriks berukuran $L \times K$ dengan elemen-elemen matriks yaitu y_{ij} , $1 \leq i \leq L$, $1 \leq j \leq K$ untuk $L \leq K$. Diberikan $L^* = \min(L, K)$, $K^* = \max(L, K)$, $N = L + K - 1$, $y_{ij}^* = y_{ij}$ untuk $L < K$, dan $y_{ij}^* = y_{ij}$ untuk kondisi yang lain.

Tahap *diagonal averaging* memindahkan matriks \mathbf{Y} ke deret y_1, \dots, y_N menggunakan persamaan:

$$y_k = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m,k-m+1}^*, & 1 \leq k \leq L^* \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m,k-m+1}^*, & 1 \leq k \leq L^* \\ \frac{1}{N-k} \sum_{m=k-K^*+1}^{N-K^*+1} y_{m,k-m+1}^*, & K^* \leq k \leq L^*. \end{cases} \quad (2.28)$$

Persamaan (2.28) berhubungan dengan rata-rata elemen matriks atas *antidiagonals* $i + j = k + 2$. Untuk pilihan $k = 1$ memberikan $y_1 = y_{1,1}$, $k = 2$ memberikan $y_2 = (y_{1,2} + y_{2,1})/2$, dan seterusnya. Perhatikan bahwa jika matriks \mathbf{Y} adalah matriks lintasan dari beberapa deret (z_1, \dots, z_N) , maka $y_i = z_i$ untuk semua i .

Jika *diagonal averaging* pada persamaan (2.28) diterapkan pada matriks \mathbf{X}_k yang dihasilkan, maka akan diperoleh suatu deret yang direkonstruksi $\tilde{F}^{(k)} = (\tilde{f}_1^{(k)}, \dots, \tilde{f}_N^{(k)})$. Oleh karena itu, deret awal f_1, \dots, f_N didekomposisi menjadi jumlah dari m deret yang direkonstruksi yaitu:

$$f_t = \sum_{k=1}^m \tilde{f}_t^{(k)}, (t = 1, 2, \dots, N). \quad (2.29)$$

2.6 Adaptive Neuro Fuzzy Inference System (ANFIS)

Adaptive Neuro Fuzzy Inference System (ANFIS) adalah sebuah kombinasi dari dua metode komputasi yaitu *artificial neural network* (ANN) atau jaringan syaraf tiruan (JST) dan logika *fuzzy*. Logika *fuzzy* memiliki kemampuan untuk mengubah aspek kualitatif pengetahuan dan wawasan seseorang ke dalam proses analisis kuantitatif yang tepat. Namun, metode ini tidak memiliki metode yang pasti yang dapat dijadikan pedoman dalam proses transformasi dan pemikiran manusia ke dalam aturan dasar *fuzzy inference system* (FIS), dan juga butuh waktu yang cukup lama untuk menyesuaikannya fungsi keanggotaan (*membership function* atau MF) (Jang, 1993). Tidak seperti JST, ANFIS memiliki kemampuan yang lebih tinggi dalam proses pembelajaran untuk beradaptasi dengan lingkungannya. Oleh karena itu, JST bisa digunakan secara otomatis untuk menyesuaikan MF dan mengurangi tingkat kesalahan dalam penentuan aturan logika *fuzzy* (Suparta & Alhasa, 2016).


2.6.1 Jaringan Adaptif

Jaringan adaptif adalah salah satu contoh jaringan syaraf tiruan (JST) ke depan dengan *multiple layers*. Jaringan adaptif memiliki karakteristik arsitektur yang terdiri dari sejumlah *node* adaptif yang saling berhubungan secara langsung tanpa adanya nilai bobot antara keduanya. Setiap *node* dalam jaringan ini memiliki fungsi dan tugas yang berbeda, serta *output* yang

bergantung pada sinyal dan parameter yang masuk ke *node*. Aturan pembelajaran yang digunakan dalam setiap *layer* dapat mempengaruhi parameter di simpul dan dapat mengurangi terjadinya kesalahan pada *output* jaringan adaptif. Biasanya digunakan kemiringan gradien atau *back propagation* dan aturan rantai dalam mempelajari jaringan adaptif dasar. Semua algoritma pembelajaran ini telah diusulkan oleh Werbos pada tahun 1970 (Jang, 1993). Masih ada kelemahan algoritma *back propagation* yang dapat mengurangi kapasitas dan akurasi jaringan adaptif dalam mengambil keputusan. Masalah utama pada *back propagation* yaitu tingkat konvergensi yang lambat dan cenderung terjebak dalam lokal minimum sehingga Jang (1993) telah mengajukan alternatif algoritma pembelajaran, yaitu algoritma pembelajaran hibrida, yang memiliki kemampuan lebih baik (Suparta & Alhasa, 2016).

2.6.2 Fuzzy Inference System (FIS)

FIS dibangun pada tiga komponen utama, yaitu basis aturan, di mana didalamnya terdapat pemilihan aturan logika *fuzzy if-then*, basis data sebagai fungsi dari himpunan keanggotaan *fuzzy*, dan penalaran FIS dari aturan dasar untuk mendapatkan *output*. FIS akan bekerja saat *input* berisi nilai aktual yang diubah menjadi nilai *fuzzy* dengan menggunakan proses fuzzifikasi melalui fungsi keanggotaannya, dimana nilai *fuzzy* memiliki rentang antara 0 dan 1. Struktur *fuzzy inference system* (FIS) secara detail dapat disajikan dalam Gambar 2.1 berikut.



Gambar 2.1 Struktur *Fuzzy Inference System* (FIS)

Aturan dasar dan basis data disebut sebagai basis pengetahuan, dimana keduanya merupakan elemen kunci dalam pembuatan keputusan. Biasanya, basis data berisi definisi seperti informasi tentang parameter himpunan *fuzzy* dengan fungsi yang telah didefinisikan untuk setiap variabel linguistik yang ada. Perkembangan basis data saat ini termasuk dalam menentukan himpunan semesta, menentukan jumlah nilai linguistik yang akan digunakan untuk setiap variabel linguistik, serta menetapkan fungsi keanggotaan. Berdasarkan peraturan, logika *fuzzy* operator dan pernyataan kondisional *if-then*. Basis aturan dapat dibangun baik dari manusia maupun pembangkitan otomatis, dimana aturan pencarian menggunakan data *input-output* dilakukan secara numerik. Ada beberapa jenis FIS, yaitu Takagi-Sugeno, Mamdani, dan Tsukamoto. FIS model Takagi-Sugeno ditemukan banyak digunakan di penerapan metode ANFIS (Suparta & Alhasa, 2016).

Metode Tsukamoto

FIS secara umum didasarkan pada penalaran yang monoton. Pada daerah konsekuen, nilai *crisp* tidak dapat diperoleh langsung pada *fire strength* antesedennya. Syarat yang harus terpenuhi pada metode Tsukamoto ini yaitu sifat monoton naik maupun monoton turun pada konsekuen himpunan *fuzzy*. Hasil inferensi setiap aturan pada metode ini memberikan *output* yang tegas (*crisp*) berdasarkan *fire strength* (w) (Kusumadewi & Hartati, 2013).

Metode Sugeno

Karakteristik FIS dengan metode Sugeno yaitu konsekuen yang digunakan bukanlah himpunan *fuzzy*, tetapi suatu persamaan linier dengan variabel-variabel yang sesuai dengan variabel-variabel *input*nya. Terdapat dua model pada metode Sugeno model *fuzzy* Sugeno orde 0 dan orde 1.

a. Model Fuzzy Sugeno Orde 0

Secara umum, model ini memiliki bentuk sebagai berikut:

$$\text{if}(x_1 \text{ is } A_1)^\circ (x_2 \text{ is } A_2)^\circ (x_3 \text{ is } A_3)^\circ \cdots (x_u \text{ is } A_R)^\circ \text{ then } y = h, \quad (2.30)$$

dimana :

x_u : variabel *input* ke- u ,

A_{r^*} : himpunan *fuzzy* ke- r^* sebagai antiseden, $r^* = 1, 2, \dots, R$,

\circ : operator *fuzzy* (misal AND atau OR),

h : parameter konsekuensi.

b. Model *Fuzzy* Sugeno Orde 1

Model *fuzzy* Sugeno orde 1 adalah sebagai berikut:

$$\text{if}(x_1 \text{ is } A_1)^\circ \cdots (x_u \text{ is } A_R)^\circ \text{ then } y = (h_{g,1} \times x_1) + \cdots + (h_{g,u^*} \times x_{u^*}) + h_{g,u^*+1}, \quad (2.31)$$

dengan h_{g,u^*} adalah konstanta atau parameter konsekuensi ke- u pada aturan ke- g . Untuk mendapatkan *output* yang tegas pada G aturan *fuzzy* maka digunakan rata-rata terbobot dalam proses agregasi dan defuzzifikasi dengan persamaan:

$$y = \frac{\sum_{g=1}^G w_g y_g}{\sum_{g=1}^G w_g}, \quad (2.32)$$


(Kusumadewi & Hartati, 2013).

2.6.3 Fungsi Keanggotaan

Fungsi keanggotaan (*membership function*) adalah suatu kurva yang menunjukkan pemetaan titik-titik *input* data ke dalam nilai atau derajat keanggotaannya. Salah satu cara yang dapat digunakan untuk mendapatkan derajat keanggotaan yaitu melalui pendekatan fungsi. Berikut disajikan beberapa fungsi yang dapat digunakan.

a. Representasi Kurva Trapezium (*Trapezoidal*)

Kurva trapesium pada dasarnya seperti bentuk segitiga, hanya saja ada beberapa titik yang memiliki nilai keanggotaan 1.



Gambar 2.2 Grafik Fungsi Trapezoidal

Parameter : $\{ a, b, c, d \}$.


Fungsi Keanggotaan :

$$\mu(x) = \begin{cases} 0, & x < a \text{ atau } x \geq d, \\ (x-a)/(b-a), & a \leq x < b, \\ 1, & b \leq x \leq c, \\ (d-x)/(d-c), & c < x \leq d. \end{cases} \quad (2.33)$$

b. Representasi Kurva Bentuk Lonceng (*Bell Curve*)

Untuk merepresentasikan bilangan *fuzzy*, biasanya digunakan kurva berbentuk lonceng. Beberapa tipe fungsi keanggotaan bentuk kurva yang disediakan MATLAB yaitu sebagai berikut.

Generalized Bell




Gambar 2.3 Grafik Fungsi Generalized Bell

Parameter : $\{ a, b, c \}$.

Fungsi keanggotaan :

$$\mu(x) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}}. \quad (2.34)$$

Kurva Phi



Gambar 2.4 Grafik Fungsi Phi

Parameter : $\{ a, b, c, d \}$.

Fungsi Keanggotaan:

$$\mu(x) = \mu_1(x) \times \mu_2(x), \quad (2.35)$$

dengan:


$$\mu_1(x) = \begin{cases} 0, & x \leq a, \\ 2[(x-a)/(b-a)]^2, & a \leq x \leq (a+b)/2, \\ 1 - 2[(b-x)/(b-a)]^2, & (a+b)/2 \leq x \leq b, \\ 1, & x \geq b, \end{cases}$$

$$\mu_2(x) = \begin{cases} 1, & x \leq c, \\ 1 - 2[(x-c)/(d-c)]^2, & c \leq x \leq (c+d)/2, \\ 2[(d-x)/(d-c)]^2, & (c+d)/2 \leq x \leq d, \\ 0, & x \geq d, \end{cases}$$

sehingga didapatkan persamaan fungsi keanggotaan:

$$\mu(x) = \begin{cases} 0, & x \leq a, \\ 2[(x-a)/(b-a)]^2, & a \leq x \leq (a+b)/2, \\ 1 - 2[(b-x)/(b-a)]^2, & (a+b)/2 \leq x \leq b, \\ 1, & b \leq x \leq c, \\ 1 - 2[(x-c)/(d-c)]^2, & c \leq x \leq (c+d)/2, \\ 2[(d-x)/(d-c)]^2, & (c+d)/2 \leq x \leq d, \\ 0, & x \geq d. \end{cases} \quad (2.36)$$

Gaussian



Gambar 2.5 Grafik Fungsi Gaussian


Parameter : $\{ \sigma, c \}$.

Fungsi Keanggotaan:

$$\mu(x) = e^{-\frac{(x-c)^2}{2\sigma^2}}. \quad (2.37)$$

2.6.4 Arsitektur ANFIS

Algoritma dalam arsitektur ANFIS memiliki fungsi yang sama dengan model FIS Takagi-Sugeno. Arsitektur ANFIS disajikan dalam Gambar 2.6.



Gambar 2.6 Arsitektur ANFIS

Berdasarkan Gambar 2.6, asumsikan terdapat dua *input* x_1 dan x_2 serta satu *output* y . Dua aturan digunakan dalam metode *if-then* untuk model Sugeno yaitu:

aturan 1 : Jika $x_1 = A_1$ dan $x_2 = B_1$ maka $y = h_{1,1}x_1 + h_{1,2}x_2 + h_{1,3}$,

aturan 2 : Jika $x_1 = A_1$ dan $x_2 = B_2$ maka $y = h_{2,1}x_1 + h_{2,2}x_1 + h_{2,3}$, dimana A_1, A_2, B_1, B_2 adalah fungsi keanggotaan dari masing-masing input x_1 dan x_2 (bagian dari premis), sedangkan $h_{1,1}, h_{1,2}, h_{1,3}$ dan $h_{2,1}, h_{2,2}, h_{2,3}$ adalah parameter linier pada bagian-*then* (bagian konsekuen) pada model Sugeno.

Arsitektur ANFIS memiliki lima *layer*. *Layer* pertama dan keempat mengandung simpul adaptif, sedangkan *layer* lainnya berisi simpul tetap. Berikut adalah penjelasan dari masing-masing *layer*.

Layer 1 : setiap *node* di *layer* ini adaptif terhadap parameter fungsi. *Output* dari masing-masing *node* adalah derajat keanggotaan yang diberikan oleh fungsi keanggotaan *input*. Misalnya, fungsi keanggotaan dapat berupa fungsi keanggotaan *Generalized Bell* sebagai berikut:

$$\mu_{A_{r^*}}(x) = \frac{1}{1 + \left| \frac{x - c_{r^*}}{a_{r^*}} \right|^{2b_{r^*}}}, \quad (2.38)$$

dimana $\mu_{A_{r^*}}$ adalah derajat keanggotaan untuk himpunan *fuzzy* A_{r^*} , x merupakan variabel *input* dan $\{a_{r^*}, b_{r^*}, c_{r^*}\}$ merupakan parameter fungsi keanggotaan yang disebut dengan parameter premis. Banyaknya fungsi keanggotaan yang digunakan disimbolkan dengan r^* .

Layer 2 : setiap *node* di *layer* ini merupakan *node* tetap atau nonadaptif berbentuk lingkaran. *Output node* merupakan hasil perkalian antara sinyal yang masuk dan yang akan dikirimkan pada *node* selanjutnya. Untuk mendapatkan tersebut diterapkan operator AND. *Output* dari *layer 2* merepresentasikan *fire strength* dari aturan ke- g (w_g).

Layer 3 : setiap *node* di *layer* ini juga merupakan *node* tetap atau nonadaptif yang berbentuk lingkaran. *Node* berupa hasil perhitungan rasio dari w_g terhadap jumlah dari keseluruhan w_g yang dinamakan *normalized firing strength* dan dapat dirumuskan sebagai:

$$\bar{w}_g = \frac{w_g}{\sum_{g=1}^G w_g} . \quad (2.39)$$

Layer 4 : setiap *node* di *layer* ini adaptif terhadap *output* yang dapat didefinisikan sebagai:

$$\bar{w}_g y_g = \bar{w}_g (h_{g,1}x_1 + h_{g,2}x_2 + h_{g,3}), \quad (2.40)$$

dimana \bar{w}_g merupakan *normalized firing strength* dan $\{h_{g,1}, h_{g,2}, h_{g,3}\}$ merupakan parameter dalam *node* yang disebut sebagai parameter linier atau parameter konsekuen.

Layer 5 : setiap *node* di *layer* ini tetap atau nonadaptif yang merupakan jumlahan dari seluruh *input*. Didefinisikan sebagai:

$$\sum_{g=1}^G \bar{w}_g y_g = \frac{\sum_{g=1}^G w_g y_g}{\sum_{g=1}^G w_g} , \quad (2.41)$$

(Suparta & Alhasa, 2016).

Output dari *layer 5* merupakan model matematis yang digunakan untuk peramalan dalam metode ANFIS.

Model persamaan (2.41) dapat dituliskan kembali dalam bentuk \hat{Y}_t yaitu:

$$\hat{Y}_t = \sum_{g=1}^G \bar{w}_{g,t} Y_{gt} = \bar{w}_{1,t} Y_{1t} + \bar{w}_{2,t} Y_{2t} + \dots + \bar{w}_{G,t} Y_{Gt}, \quad (2.42)$$

dengan:


g : banyaknya aturan (*rule*), $g = 1, 2, \dots, G$,

t : periode pengamatan, $t = 1, 2, \dots, N$,


$\bar{w}_{g,t}$: *normalized firing strength* aturan ke- g pada periode ke- t .

2.7 Singular Spectrum Analysis dan Adaptive Neuro Fuzzy Inference System

Deret Y_t didekomposisi menjadi deret *trend* (T_t), deret musiman atau *seasonality* (S_t) dan deret *noise* atau *error* (N_t^*) pada tahap SSA. Tahapan SSA hanya sampai pada proses dekomposisi, untuk peramalan SSA dapat digunakan berbagai macam metode peramalan misalnya ANFIS. Peramalan dapat dilakukan secara individu maupun agregat. Peramalan individu yaitu menerapkan metode peramalan pada masing-masing komponen atau *eigentruple* hasil dekomposisi yang terdiri dari *eigentruple* utama dan *eigentruple noise*. Peramalan agregat yaitu menerapkan metode peramalan pada kelompok-kelompok hasil rekonstruksi yaitu kelompok *trend*, *seasonality* dan *noise*. Perlu diketahui bahwa *noise* pada peramalan individu bisa saja berbeda dari *noise* yang ada pada peramalan agregat. Hal ini dikarenakan *noise* pada peramalan agregat merupakan rekonstruksi dari *eigentruple* yang tidak memiliki periode maupun yang memiliki periode musiman namun tidak sesuai dengan periode musiman bulan. *Noise* pada peramalan individu merupakan keseluruhan *eigentruple* yang tidak memiliki periode yaitu *eigentruple* selain *eigentruple* utama. Alur peramalan SSA-ANFIS secara agregat dan individu dapat dilihat pada Gambar 2.7 dan Gambar 2.8.



Gambar 2.7 Alur Peramalan Individu SSA-ANFIS



Gambar 2.8 Alur Peramalan Agregat SSA-ANFIS

Model peramalan individu SSA-ANFIS yang dihasilkan merupakan jumlahan dari model ANFIS pada tiap komponen sebanyak m komponen yaitu:

$$\begin{aligned}
 \hat{Y}_t &= \hat{PC}_{1t} + \hat{PC}_{2t} + \dots + \hat{PC}_{mt} + \hat{PC}_{noise} \\
 &= (\bar{w}_{1,t}Y_{1t} + \bar{w}_{2,t}Y_{2t} + \dots + \bar{w}_{G,t}Y_{Gt})_1 \\
 &\quad + (\bar{w}_{1,t}Y_{1t} + \bar{w}_{2,t}Y_{2t} + \dots + \bar{w}_{G,t}Y_{Gt})_2 + \dots \\
 &\quad + (\bar{w}_{1,t}Y_{1t} + \bar{w}_{2,t}Y_{2t} + \dots + \bar{w}_{G,t}Y_{Gt})_m \\
 &\quad + (\bar{w}_{1,t}Y_{1t} + \bar{w}_{2,t}Y_{2t} + \dots + \bar{w}_{G,t}Y_{Gt})_{noise}.
 \end{aligned} \tag{2.43}$$

Selanjutnya model peramalan agregat SSA-ANFIS dapat dilihat pada persamaan 2.43. Model ini merupakan jumlahan dari model ANFIS pada kelompok *trend*, *seasonality* dan *noise*.

$$\begin{aligned}
 \hat{Y}_t &= \hat{PC}_{trend} + \hat{PC}_{seasonaliy} + \hat{PC}_{noise} \\
 &= (\bar{w}_{1,t}Y_{1t} + \bar{w}_{2,t}Y_{2t} + \dots + \bar{w}_{G,t}Y_{Gt})_{trend} \\
 &\quad + (\bar{w}_{1,t}Y_{1t} + \bar{w}_{2,t}Y_{2t} + \dots + \bar{w}_{G,t}Y_{Gt})_{seasonaliy} \\
 &\quad + (\bar{w}_{1,t}Y_{1t} + \bar{w}_{2,t}Y_{2t} + \dots + \bar{w}_{G,t}Y_{Gt})_{noise}
 \end{aligned} \tag{2.44}$$

2.8 Evaluasi Model

Kriteria evaluasi model yang digunakan pada penelitian ini yaitu nilai *root mean square error* (RMSE) *out-sample* yang dirumuskan sebagai:

$$RMSE = \sqrt{\frac{1}{m^*} \sum_{t=n+1}^N (Y_t - \hat{Y}_t)^2}. \quad (2.45)$$

Kriteria RMSE merupakan kriteria yang umum dan sering digunakan untuk evaluasi model ramalan. Penggunaan kriteria evaluasi model antara kriteria satu dengan yang lain dapat menghasilkan keputusan berbeda-beda sehingga pada penelitian ini tidak hanya digunakan satu kriteria untuk evaluasi model. Kriteria selanjutnya yang digunakan yaitu *mean absolute percentage error* (MAPE) yang dirumuskan sebagai berikut:

$$MAPE = \frac{1}{m^*} \sum_{t=n+1}^N \frac{|Y_t - \hat{Y}_t|}{Y_t} \times 100\%. \quad (2.46)$$

J. Scott Armstrong (1983) menyebutkan tiga keunggulan MAPE yaitu MAPE dapat digunakan pada berbagai organisasi, mudah diinterpretasikan dan digunakan secara umum. Selain MAPE, digunakan nilai *symmetric mean absolute percentage error* (sMAPE) yaitu:

$$sMAPE = \frac{1}{m^*} \sum_{t=n+1}^N \frac{|Y_t - \hat{Y}_t|}{(Y_t + \hat{Y}_t)/2} \times 100\%. \quad (2.47)$$

Y_t merupakan data aktual dan \hat{Y}_t merupakan data hasil ramalan. Kriteria ini dapat digunakan pada nilai *error* yang besar saat data aktual mendekati nol. Keunggulan lainnya yaitu dapat menghindari besarnya selisih antar nilai mutlak persentase *error* saat Y_t lebih besar dari \hat{Y}_t . Selain itu sMAPE memiliki fluktuasi antara -200% sampai 200% sedangkan ukuran *non-symmetric* tidak memiliki batas. Selanjutnya juga digunakan kriteria evaluasi model yang lain yaitu *symmetric median absolute percentage error* (sMdAPE). Kriteria tersebut lebih kuat dan tahan terhadap nilai yang *extreme* dibandingkan dengan *average absolute percentage error* (Makridakis & Hibon, 2000). Persamaan yang digunakan untuk menentukan nilai sMdAPE yaitu:

$$sMdAPE = \text{median} \left(\frac{|Y_t - \hat{Y}_t|}{(Y_t + \hat{Y}_t)/2} \right) \times 100\%. \quad (2.48)$$

Model terbaik merupakan model dengan nilai kriteria evaluasi model terkecil (Wei, 2006).

2.9 *Inflow dan Outflow Uang Kartal*

Uang didefinisikan sebagai segala sesuatu yang diterima secara umum sebagai alat pembayaran yang resmi. Ada tiga tujuan uang berdasarkan penggunaannya.

1. Uang digunakan sebagai alat tukar untuk pembayaran di antara konsumen, badan usaha dan pemerintah.
2. Uang sebagai satuan dasar untuk menilai daya beli atau nilai yang dibayarkan untuk memperoleh barang dan jasa.
3. Uang sebagai alat penyimpanan nilai untuk mengukur nilai ekonomis pendapatan di masa sekarang terhadap pengeluaran di masa yang akan datang.

Bentuk lain dan uang adalah komoditas uang (emas dan perak batangan dan uang logam, *brightly coloured & shells*, dan lain-lain), barter, perdagangan barang dan jasa tanpa pertukaran uang (*monetary exchange*). Saat ini uang kertas hanya menunjukkan sebagian kecil dari cadangan uang di suatu negara. Sekiranya 3/4 dari penawaran uang dilakukan dalam bentuk debit dan kredit saldo rekening giro di bank umum (uang giral).

Inflow uang kartal merupakan aliran informasi mengenai uang kertas dan logam yang masuk dari perbankan dan masyarakat ke Bank Indonesia (BI). Informasi tersebut terdiri dari setoran bank dan non bank, transaksi masuk kas titipan, serta penukaran masuk loket BI dan kas keliling. *Outflow* uang kartal merupakan aliran informasi mengenai uang kertas dan logam yang keluar dari BI kepada perbankan dan masyarakat. Informasi pada *outflow* terdiri dari pembayaran bank dan non bank, transaksi keluar kas titipan, serta penukaran ke loket BI dan kas keliling (Bank Indonesia, 2017).

BAB III METODOLOGI PENELITIAN

Penelitian ini membahas dua kajian yaitu kajian simulasi dan kajian terapan. Kajian simulasi dilakukan untuk memahami pola data dari hasil dekomposisi metode SSA serta mengetahui peforma metode SSA-ANFIS dalam meramalkan data dengan efek variasi kalender. Pada kajian terapan, metode SSA-ANFIS diterapkan untuk data *inflow* dan *outflow* uang kartal per pecahan di Indonesia.

3.1 Kajian Simulasi

Kajian simulasi dilakukan dengan menggunakan data simulasi yang dibangkitkan dalam beberapa ketentuan yaitu efek variasi kalender hari raya Idul Fitri, pola data, dan jenis *noise*. Banyaknya data simulasi yang dibangkitkan yaitu 168 data. Secara keseluruhan, model simulasi yang digunakan pada kedua skenario ditunjukkan oleh persamaan:

$$Y_t = T_t + M_t + V_t + E_t, \quad (3.1)$$

dengan:

- T_t : Komponen *trend* periode ke- t ,
- M_t : Komponen musiman periode ke- t ,
- V_t : Komponen variasi kalender periode ke- t ,
- E_t : Komponen *noise* atau *error* periode ke- t .

Berikut dijelaskan pembangkitan data yang dilakukan pada masing-masing komponen data simulasi.

a. Komponen *Trend*

Pola *trend* merupakan pola yang menunjukkan kenaikan atau penurunan pada suatu data. Pembangkitan data simulasi pada komponen *trend* menggunakan persamaan:

$$T_t = \beta t, \quad (3.2)$$

dengan β merupakan koefisien *trend* yang pada penelitian ini digunakan $\beta = 0,3$.

b. Komponen Musiman

Pola musiman yaitu pola yang memiliki perulangan nilai pada periode tertentu. Persamaan yang digunakan untuk membangkitkan komponen musiman bulan yaitu:

$$M_t = a + b \sin\left(\frac{2\pi t}{12}\right). \quad (3.3)$$

Pada kajian simulasi ini digunakan nilai parameter $a=15$ dan $b=7$.

c. Komponen Variasi Kalender

Data dengan efek variasi kalender yaitu data yang memiliki pengaruh pada kejadian-kejadian khusus tertentu. Kejadian khusus yang digunakan dalam penelitian ini adalah terjadinya hari raya Idul Fitri. Simulasi data yang dilakukan merupakan simulasi data *outflow* sehingga digunakan efek variasi kalender saat terjadi hari Raya Idul Fitri dan satu bulan sebelumnya. Efek variasi kalender dibangkitkan dengan persamaan:

$$V_t = 23V_{1,t} + 30V_{2,t} + 43V_{3,t} + 44V_{4,t} + 46V_{1,t-1} + 38V_{2,t-1} + 27V_{3,t-1} + 29V_{4,t-1}, \quad (3.4)$$

dengan:

V_t : Efek variasi kalender,

$V_{j,t}$: *Dummy* variasi kalender untuk minggu ke- j periode ke- t ,
 $j=1,2,3,4$,

$V_{j,t-1}$: *Dummy* variasi kalender satu bulan sebelumnya untuk minggu ke- j periode ke- t , $j=1,2,3,4$.

d. Komponen *Noise*

Komponen *noise* yang dibangkitkan terdiri dari *noise random* dan *noise tidak random*. *Noise random* mengikuti pola distribusi Normal (0,1) dan *noise tidak random* yaitu *noise* yang mengikuti pola AR(1). Keduanya ditunjukkan dengan persamaan:

$$E_t = a_t \text{ dengan } a_t \sim \text{Normal}(0,1) \quad (3.5)$$


$$E_t = 0,8E_{t-1} + a_t \text{ dengan } a_t \sim \text{Normal}(0,1) \quad (3.6)$$

Selanjutnya disajikan langkah-langkah analisis yang dilakukan pada kajian simulasi.

1. Membangkitkan data simulasi sebanyak 168 data dengan ketentuan:
 - a. Komponen *trend* dibangkitkan seperti persamaan (3.2),
 - b. Komponen musiman dibangkitkan dengan persamaan (3.3),
 - c. Komponen variasi kalender dibangkitkan dengan persamaan (3.4),
 - d. Komponen *noise* dibangkitkan seperti persamaan (3.5) dan (3.6).
2. Membentuk dua skenario data simulasi seperti persamaan (3.1). Perbedaan skenario pertama dan skenario kedua yaitu pada jenis *noise* yang digunakan. Skenario pertama menggunakan *noise random* dan skenario kedua menggunakan *noise tidak random*.
2. Menerapkan metode *singular spectrum analysis* dan *adaptive neuro fuzzy inference system* (SSA-ANFIS) pada tiap skenario data simulasi dengan tahapan sebagai berikut:
 - a. Menentukan *window length* (L) dari data simulasi.
 - b. Membentuk matriks lintasan \mathbf{X} yang dibangun dari deret F .
 - c. Melakukan dekomposisi nilai singular dari matriks lintasan \mathbf{X} untuk mendapatkan *eigentruple* dari matriks tersebut.
 - d. Melakukan tahap pengelompokan yaitu melakukan pengelompokan *eigentruple* menjadi tiga kelompok *noise*, *trend* dan *seasonality* yang dapat dilakukan melalui pemeriksaan grafik dari nilai singular dan grafik satu dimensi dari deret yang direkonstruksi. *Eigentruple* dengan pola variasi lambat dikelompokkan kedalam kelompok *trend* sedangkan *eigentruple* berpasangan dengan pola variasi lebih cepat dengan periode yang sama antar pasangan dikelompokkan ke dalam kelompok *seasonality*. Selebihnya merupakan kelompok *noise*.


- e. Melakukan tahapan *diagonal averaging* yaitu merekonstruksi kembali tiap *eigentriple* yang menjadi anggota kelompok *trend*, *seasonality* dan *noise*.
- f. Melakukan algoritma dari peramalan *adaptive neuro-fuzzy inference system* (ANFIS). Peramalan dilakukan dalam 2 jenis yaitu peramalan secara agregat dan peramalan secara individu. Peramalan agregat berarti melakukan metode peramalan ANFIS terhadap masing-masing kelompok *trend*, *seasonality*, dan *noise* sedangkan peramalan individu berarti melakukan peramalan ANFIS terhadap masing-masing *eigentriple* hasil dekomposisi. Berikut dijelaskan mengenai tahapan-tahapan pada metode peramalan ANFIS.
 - (i). Menentukan variabel *input*.
 - (ii). Menentukan jumlah fungsi keanggotaan.
 - (iii). Menentukan jenis fungsi keanggotaan.
 - (iv). Melakukan iterasi sehingga didapatkan nilai parameter yang konvergen dengan *error* minimum.
 - (v). Meramalkan masing-masing kombinasi jenis dan jumlah fungsi keanggotaan.
 - (vi). Menentukan model terbaik dari model-model yang digunakan pada masing-masing kombinasi jenis dan jumlah fungsi keanggotaan menggunakan nilai RMSE *out-sample*.
- g. Mendapatkan hasil ramalan SSA-ANFIS dengan cara agregasi. Hasil ramalan agregat didapatkan dengan menjumlahkan hasil ramalan *trend*, *seasonality* dan *noise* sedangkan hasil ramalan individu didapatkan dengan menjumlahkan hasil ramalan tiap *eigentriple* utama dan *eigentriple noise*.
4. Membandingkan performa hasil peramalan agregat dan individu pada dua skenario simulasi.
5. Mengambil kesimpulan

Langkah-langkah analisis kajian simulasi dapat digambarkan dalam diagram alir pada Gambar 3.1.



Gambar 3.1 Diagram Alir Analisis Kajian Simulasi (SSA-ANFIS)

Langkah-langkah analisis untuk algoritma peramalan ANFIS dapat disajikan dalam Gambar 3.2.



Gambar 3.2 Diagram Alir Algoritma Peramalan ANFIS

3.2 Kajian Terapan

Berikut merupakan penjelasan mengenai data, variabel, serta langkah analisis yang digunakan dalam kajian terapan.

3.2.1 Sumber Data

Data yang digunakan dalam kajian terapan yaitu data sekunder yang didapatkan dari Bank Indonesia pusat pada Tugas

Akhir Priyandari Dina Saputri, mahasiswi Departemen Statistika Institut Teknologi Sepuluh Nopember berupa data *inflow* dan *outflow* nasional uang kartal kertas pecahan perbulan periode Januari 2003 sampai dengan Desember 2016. Pecahan tersebut terdiri dari pecahan Rp 100.000,00, Rp 50.000,00, Rp 20.000,00, Rp 10.000,00, Rp 5.000,00, Rp 2.000,00 dan Rp 1.000,00. Data *inflow* dan *outflow* ini dapat disajikan dalam Lampiran 1 sedangkan surat keterangan penggunaan data tersebut terlampir pada Lampiran 2.

3.2.2 Variabel Penelitian

Variabel penelitian yang digunakan dalam penelitian ini dapat disajikan dalam Tabel 3.1.

Tabel 3.1 Variabel Penelitian

Data	Variabel	Keterangan
<i>Inflow</i>	$Y_{1,t}$	Pecahan Rp. 100.000,00 pada bulan ke- t
	$Y_{2,t}$	Pecahan Rp. 50.000,00 pada bulan ke- t
	$Y_{3,t}$	Pecahan Rp. 20.000,00 pada bulan ke- t
	$Y_{4,t}$	Pecahan Rp. 10.000,00 pada bulan ke- t
	$Y_{5,t}$	Pecahan Rp. 5.000,00 pada bulan ke- t
	$Y_{6,t}$	Pecahan Rp. 2.000,00 pada bulan ke- t
	$Y_{7,t}$	Pecahan Rp. 1.000,00 pada bulan ke- t
<i>Outflow</i>	$Y_{8,t}$	Pecahan Rp. 100.000,00 pada bulan ke- t
	$Y_{9,t}$	Pecahan Rp. 50.000,00 pada bulan ke- t
	$Y_{10,t}$	Pecahan Rp. 20.000,00 pada bulan ke- t
	$Y_{11,t}$	Pecahan Rp. 10.000,00 pada bulan ke- t
	$Y_{12,t}$	Pecahan Rp. 5.000,00 pada bulan ke- t
	$Y_{13,t}$	Pecahan Rp. 2.000,00 pada bulan ke- t
	$Y_{14,t}$	Pecahan Rp. 1.000,00 pada bulan ke- t

Tabel 3.2 berikut menunjukkan struktur data yang digunakan dalam penelitian ini.

Tabel 3.2 Struktur Data Penelitian

Tahun	Bulan	<i>Inflow</i>						
		$Y_{1,t}$	$Y_{2,t}$	$Y_{3,t}$	$Y_{4,t}$	$Y_{5,t}$	$Y_{6,t}$	$Y_{7,t}$
2003	Januari	$Y_{1,1}$	$Y_{2,1}$	$Y_{3,1}$	$Y_{4,1}$	$Y_{5,1}$	$Y_{6,1}$	$Y_{7,1}$
2003	Februari	$Y_{1,2}$	$Y_{2,2}$	$Y_{3,2}$	$Y_{4,2}$	$Y_{5,2}$	$Y_{6,2}$	$Y_{7,2}$
2003	Maret	$Y_{1,3}$	$Y_{2,3}$	$Y_{3,3}$	$Y_{4,3}$	$Y_{5,3}$	$Y_{6,3}$	$Y_{7,3}$
2003	April	$Y_{1,4}$	$Y_{2,4}$	$Y_{3,4}$	$Y_{4,4}$	$Y_{5,4}$	$Y_{6,4}$	$Y_{7,4}$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
2016	November	$Y_{1,167}$	$Y_{2,167}$	$Y_{3,167}$	$Y_{4,167}$	$Y_{5,167}$	$Y_{6,167}$	$Y_{7,167}$
2016	Desember	$Y_{1,168}$	$Y_{2,168}$	$Y_{3,168}$	$Y_{4,168}$	$Y_{5,168}$	$Y_{6,168}$	$Y_{7,168}$

Tahun	Bulan	<i>Outflow</i>						
		$Y_{8,t}$	$Y_{9,t}$	$Y_{10,t}$	$Y_{11,t}$	$Y_{12,t}$	$Y_{13,t}$	$Y_{14,t}$
2003	Januari	$Y_{8,1}$	$Y_{9,1}$	$Y_{10,1}$	$Y_{11,1}$	$Y_{12,1}$	$Y_{13,1}$	$Y_{14,1}$
2003	Februari	$Y_{8,2}$	$Y_{9,2}$	$Y_{10,2}$	$Y_{11,2}$	$Y_{12,2}$	$Y_{13,2}$	$Y_{14,2}$
2003	Maret	$Y_{8,3}$	$Y_{9,3}$	$Y_{10,3}$	$Y_{11,3}$	$Y_{12,3}$	$Y_{13,3}$	$Y_{14,3}$
2003	April	$Y_{8,4}$	$Y_{9,4}$	$Y_{10,4}$	$Y_{11,4}$	$Y_{12,4}$	$Y_{13,4}$	$Y_{14,4}$
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
2016	November	$Y_{8,167}$	$Y_{9,167}$	$Y_{10,167}$	$Y_{11,167}$	$Y_{12,167}$	$Y_{13,167}$	$Y_{14,167}$
2016	Desember	$Y_{8,168}$	$Y_{9,168}$	$Y_{10,168}$	$Y_{11,168}$	$Y_{12,168}$	$Y_{13,168}$	$Y_{14,168}$

Variabel *dummy* yang digunakan dalam penelitian ini dapat disajikan dalam Tabel 3.3.

Tabel 3.3 Variabel *Dummy* yang Digunakan

<i>Dummy</i>		Keterangan
<i>Trend</i>	T_t^*	<i>Dummy trend</i> periode ke- t dengan $t=1,2,...,168$
Musiman	$M_{1,t}$	<i>Dummy</i> musiman bulan Januari periode ke- t
	$M_{2,t}$	<i>Dummy</i> musiman bulan Februari periode ke- t
	\vdots	\vdots
	$M_{12,t}$	<i>Dummy</i> musiman bulan Desember periode ke- t

Tabel 3.3 Variabel *Dummy* yang Digunakan (Lanjutan)

<i>Dummy</i>	Keterangan	
Variasi Kalender	$V_{j,t}$	<i>Dummy</i> variasi kalender untuk Idul Fitri pada minggu ke- j periode ke- t , $j=1,2,3,4$
	$V_{j,t-1}$	<i>Dummy</i> variasi kalender satu bulan sebelum Idul Fitri pada minggu ke- j periode ke- t , $j=1,2,3,4$
	$V_{j,t+1}$	<i>Dummy</i> variasi kalender satu bulan setelah Idul Fitri pada minggu ke- j periode ke- t , $j=1,2,3,4$

Perhitungan minggu dalam satu bulan pada variasi kalender di atas yaitu minggu ke-1 dihitung mulai tanggal 1 sampai tanggal 7, minggu ke-2 dihitung mulai tanggal 8 sampai tanggal 15, minggu ke-3 dihitung mulai tanggal 16 sampai tanggal 23, dan minggu ke-4 dihitung mulai tanggal 24 sampai akhir tanggal bulan tersebut (Bank Indonesia, 2013).

Berikut disajikan tabel terjadinya hari raya Idul Fitri tahun 2003 sampai tahun 2017.

Tabel 3.4 Identifikasi Variabel *Dummy* Variasi Kalender Idul Fitri Tahun 2003-2016


Tahun	Tanggal	Minggu ke- j	Variabel <i>Dummy</i>		
			$V_{j,t-1}$	$V_{j,t}$	$V_{j,t+1}$
2003	25-26 November	Minggu ke-4	Oktober	November	Desember
2004	13-14 November	Minggu ke-2	Oktober	November	Desember
2005	03-04 November	Minggu ke-1	Oktober	November	Desember
2006	23-24 Oktober	Minggu ke-4	September	Oktober	November
2007	12-13 Oktober	Minggu ke-2	September	Oktober	November
2008	1-2 Oktober	Minggu ke-1	September	Oktober	November
2009	20-21 September	Minggu ke-3	Agustus	September	Oktober
2010	09-10 September	Minggu ke-2	Agustus	September	Oktober
2011	30-31 Agustus	Minggu ke-4	Juli	Agustus	September
2012	18-19 Agustus	Minggu ke-3	Juli	Agustus	September
2013	08-09 Agustus	Minggu ke-2	Juli	Agustus	September
2014	28-29 Juli	Minggu ke-4	Juni	Juli	Agustus
2015	19-20 Juli	Minggu ke-3	Juni	Juli	Agustus
2016	06-07 Juli	Minggu ke-1	Juni	Juli	Agustus

3.23 Langkah Analisis

Langkah analisis yang disusun dalam penelitian ini disesuaikan dengan tujuan penelitian yang ingin dicapai. Berikut ini merupakan langkah-langkah analisis yang dilakukan pada kajian terapan.


1. Melakukan analisis statistika deskriptif untuk mengetahui karakteristik data *inflow* dan *outflow* uang kartal per pecahan.
2. Menerapkan metode ARIMAX pada data *inflow* dan *outflow* uang kartal per pecahan. Tahapan-tahapn pada metode ARIMAX yaitu:
 - a. Membagi data ke dalam data *in-sample* dan *out-sample*.
 - b. Menentukan variabel *dummy* untuk *trend*, musiman dan variasi kalender.
 - c. Melakukan regresi pada data dengan variabel prediktor berupa variabel *dummy* musiman, *trend* dan variasi kalender hari raya Idul Fitri.
 - d. Tahap identifikasi orde p dan q melalui plot ACF dan PACF.
 - e. Cek diagnosa *error*.
 - f. Estimasi parameter.
 - g. Cek diagnosa kembali.
 - h. Melakukan peramalan dengan metode ARIMAX.
3. Menerapkan metode hibrida SSA-ANFIS pada data *inflow* dan *outflow* uang kartal per pecahan.
4. Membandingkan nilai RMSE, MAPE, sMAPE dan sMdAPE ketiga model peramalan untuk memilih model mana yang paling baik untuk meramalkan data *inflow* dan *outflow* uang kartal per pecahan.

Langkah-langkah analisis pada kajian terapan dapat digambarkan dalam Gambar 3.3.



Gambar 3.3 Diagram Alir Analisis Kajian Terapan

Langkah-langkah metode ARIMAX dapat divisualisasikan pada Gambar 3.4.




Gambar 3.4 Diagram Alir Metode ARIMAX

BAB IV ANALISIS DAN PEMBAHASAN

Penelitian ini membahas dua kajian yaitu kajian simulasi dan kajian terapan. Metode SSA-ANFIS digunakan pada kedua kajian, namun pada kajian terapan metode tersebut dibandingkan dengan metode ARIMAX. Selanjutnya dilakukan pemilihan metode terbaik dengan membandingkan nilai RMSE, MAPE, sMAPE, dan sMdaPE pada data *out-sample*. Model terbaik digunakan untuk meramalkan *inflow* dan *outflow* uang kertas per pecahan di Indonesia.

4.1 Kajian Simulasi


Terdapat dua skenario yang digunakan dalam kajian simulasi. Keduanya mengandung pola *trend*, musiman, efek variasi kalender dan *noise* tertentu. Plot dari pola data *trend*, musiman, dan efek variasi kalender hari raya Idul Fitri dapat disajikan dalam Gambar 4.1.



Gambar 4.1 Time Series Plot (a) Komponen *Trend* (b) Komponen Musiman (c) Efek Variasi Kalender


Berdasarkan Gambar 4.1 dapat dilihat bahwa pola *trend* menyebabkan kenaikan data setiap pertambahan waktu. Pada pola data musiman terlihat bahwa pola data pengamatan memiliki nilai yang sama pada bulan yang sama. Efek variasi kalender yang digunakan menunjukkan nilai-nilai yang tinggi pada kejadian hari raya Idul Fitri.

Perbedaan dari dua skenario yang dibangkitkan yaitu jenis *noise* yang digunakan. Gambar 4.2 berikut menunjukkan *time series plot* komponen *noise* yang dibangkitkan.



Gambar 4.2 Time Series Plot (a) Noise Random (b) Noise Tidak Random

Plot *noise* pada Gambar 4.2 tidak menunjukkan perbedaan yang signifikan sehingga untuk melihat perbedaan pola *noise*, berikut disajikan *scatter plot noise* waktu ke- t dengan *noise* waktu ke- $t-1$.




Gambar 4.3 Scatter Plot Noise Waktu ke- t dengan Noise Waktu ke- $t-1$
(a) Noise Random (b) Noise Tidak Random

Scatter plot pada Gambar 4.3 memperlihatkan dengan jelas perbedaan antara *noise random* dan *noise tidak random*. *Noise random* cenderung membentuk plot yang tidak beraturan sedangkan *noise tidak random* cenderung membentuk suatu pola tertentu.

4.1.1 Skenario Pertama

Data simulasi yang digunakan pada skenario pertama yaitu data yang memiliki variasi kalender dengan pola data *trend* dan musiman serta memiliki *noise random*. Data simulasi pada skenario pertama dapat disajikan dalam Gambar 4.4.



Gambar 4.4 Time Series Plot Skenario Pertama


Gambar 4.4 menunjukkan bahwa data simulasi skenario pertama mengandung pola *trend*, musiman, dan variasi kalender hari raya Idul Fitri. Bulan terjadinya hari raya Idul Fitri ditunjukkan dengan garis biru putus-putus.

Data pada skenario pertama ini disimulasikan terhadap metode SSA-ANFIS. Terdapat dua tahapan dalam SSA yaitu dekomposisi dan rekonstruksi. Tahap dekomposisi diawali dengan mendefinisikan deret F yang merupakan data simulasi skenario pertama sehingga $F = \{18, 162, 22, 233, \dots, 65, 656\}$. Langkah selanjutnya menentukan parameter *window length* (L). Besarnya nilai L yang digunakan dalam penelitian ini sesuai dengan *default* MATLAB yang dirumuskan dengan $L = (N+1)/2$ sehingga $L = (168+1)/2 = 84,5 \approx 85$.

Matriks lintasan \mathbf{X} yang terbentuk pada skenario pertama berdasarkan deret F dengan $L=85$ yaitu:


$$\mathbf{X} = (x_{ij})_{i,j=1}^{85,84} = \begin{bmatrix} 18,162 & 22,233 & \cdots & 38,876 \\ 22,233 & 22,604 & \cdots & 41,387 \\ \vdots & \vdots & \ddots & \vdots \\ 41,387 & 46,237 & \cdots & 65,656 \end{bmatrix}.$$

Langkah berikutnya adalah dekomposisi nilai singular (SVD) untuk mendapatkan *eigentruple* dari matriks lintasan \mathbf{X} . Matriks lintasan \mathbf{X} didekomposisi menjadi 50 *eigentruple*. Plot nilai singular dari 50 *eigentruple* hasil dekomposisi dapat dilihat pada Gambar 4.5.



Gambar 4.5 Plot Nilai Singular Skenario Pertama

Selanjutnya rekonstruksi SSA yaitu pengelompokan *eigentruple* ke dalam kelompok *trend*, *seasonality*, dan *noise*. Plot nilai singular yang menurun secara lambat merupakan kelompok *noise*. Gambar 4.5 memperlihatkan *eigentruple* 12 sampai dengan *eigentruple* 50 menurun secara lambat sehingga *eigentruple* tersebut dikelompokkan ke dalam kelompok *noise*. *Eigentruple* selain kelompok *noise* yaitu 11 *eigentruple* awal merupakan *eigentruple* utama. *Eigentruple* utama merupakan *eigentruple* pembangun kelompok *trend* dan *seasonality*, namun pada pengecualian tertentu *eigentruple* utama bisa menjadi kelompok *noise*. Selanjutnya disajikan plot dari *eigentruple* utama untuk menentukan *eigentruple* yang termasuk kelompok *trend* dan kelompok *seasonality*.



Gambar 4.6 Plot *Eigentriple* Utama pada Skenario Pertama


Sumbu horizontal yang digunakan pada plot *eigentriple* pada Gambar 4.6 merupakan periode tahunan dari data sedangkan sumbu vertikal merupakan besarnya data simulasi skenario pertama. *Eigentriple* dengan pola variasi lambat dikelompokkan ke dalam kelompok *trend*. *Eigentriple* 1 merupakan kelompok *trend* karena memiliki pola variasi yang lambat. Kelompok *seasonality* dicirikan dengan pola variasi *eigentriple* lebih cepat dan memiliki periode yang sama pada 2 *eigentriple* berurutan. Dapat dilihat pada Gambar 4.6, pola yang ditunjukkan *eigentriple* 2 dan *eigentriple* 3 hampir sama. Begitu pula untuk *eigentriple* 4 dan *eigentriple* 5, *eigentriple* 6 dan *eigentriple* 7, *eigentriple* 8 dan *eigentriple* 9, *eigentriple* 10 dan *eigentriple* 11. *Eigentriple-eigentriple* tersebut dapat diduga sebagai kelompok *seasonality*.

Berikut disajikan tabel pengelompokan 11 *eigentruple* beserta periode musiman yang terbentuk.


Tabel 4.1 Pengelompokan *Eigentruple* Skenario Pertama

<i>Eigentruple</i>	Periode (Bulan)	<i>Eigentruple</i>	Periode (Bulan)
1	-	6	11
2	6	7	11
3	6	8	3
4	4	9	3
5	4	10	2
		11	2

Eigentruple dengan periode musiman yang sama dikelompokkan ke dalam kelompok *seasonality*. Berdasarkan Tabel 4.1 didapatkan anggota kelompok *seasonality* yaitu *eigentruple* 2, *eigentruple* 3, *eigentruple* 4, *eigentruple* 5, *eigentruple* 8, *eigentruple* 9, *eigentruple* 10, dan *eigentruple* 11. *Eigentruple* 6 dan *eigentruple* 7 tidak dikelompokkan ke dalam kelompok *seasonality* karena periode 11 tidak dapat diaplikasikan pada data bulanan. Kedua *eigentruple* tersebut kemudian dikelompokkan ke dalam kelompok *noise*. Tahapan SSA yang terakhir yaitu *diagonal averaging* atau tahap penggabungan *eigentruple* (rekonstruksi) pada setiap kelompok. Hasil rekonstruksi kelompok *trend*, *seasonality* dan *noise* dapat disajikan dalam Gambar 4.7.



Gambar 4.7 Plot Hasil Rekonstruksi (a) *Trend* (b) *Seasonality* (c) *Noise* pada Skenario Pertama



Gambar 4.7 Plot Hasil Rekonstruksi (a) *Trend* (b) *Seasonality* (c) *Noise* pada Skenario Pertama (Lanjutan)

Setelah didapatkan hasil rekonstruksi seperti pada Gambar 4.7, langkah selanjutnya yaitu peramalan pada hasil dekomposisi SSA. Terdapat dua jenis peramalan yang dilakukan yaitu peramalan individu dan peramalan agregat. Peramalan agregat adalah melakukan peramalan terhadap hasil rekonstruksi kelompok *trend*, kelompok *seasonality* dan kelompok *noise*. Peramalan individu yaitu melakukan peramalan terhadap masing-masing *eigentriple* yang terbentuk. *Eigentriple* yang terbentuk dibedakan atas *eigentriple* utama dan *eigentriple* noise. Peramalan individu hanya dilakukan pada *eigentriple* utama saja sedangkan *eigentriple* noise diramalkan secara agregat. Metode peramalan yang digunakan yaitu metode peramalan ANFIS. Hasil ramalan secara keseluruhan diperoleh dengan menjumlahkan hasil ramalan pada tiap-tiap dekomposisi baik pada peramalan individu maupun agregat.

a. Peramalan Agregat

Langkah awal yang ditempuh dalam peramalan menggunakan metode ANFIS yaitu menentukan variabel *input*. Variabel *input* yang digunakan yaitu *lag* PACF yang signifikan dari data yang sudah stasioner. Uji yang dapat digunakan untuk menguji kestasioneritasan data yaitu uji Dickey-Fuller. Hasil uji Dickey-Fuller untuk ketiga kelompok hasil dekomposisi disajikan dalam Tabel 4.2.

Tabel 4.2 Uji Dickey-Fuller pada Data Skenario Pertama


Kelompok	Dickey-Fuller	<i>P-value</i>
<i>Trend</i>	-1,058	0,93
<i>Seasonality</i>	-23,434	< 0,01
<i>Noise</i>	-10,617	< 0,01

Jika ditetapkan taraf signifikansi 0,05 maka berdasarkan *p-value* untuk kelompok *trend* pada Tabel 4.2 keputusan pengujian ini yaitu gagal tolak H_0 , dimana H_0 atau hipotesis awal yang digunakan dalam uji Dickey-Fuller yaitu data tidak stasioner. Dengan demikian, dapat disimpulkan jika data *trend* tidak stasioner sedangkan data *seasonality* dan *noise* sudah stasioner. Agar data *trend* menjadi stasioner dapat dilakukan *differencing lag* yang kemudian diuji kembali kestasioneran data *differencing* tersebut seperti pada Tabel 4.3.

Tabel 4.3 Uji Dickey-Fuller pada Data *Trend* Skenario Pertama Setelah *Differencing*

Kelompok	Dickey-Fuller	<i>P-value</i>
<i>Trend</i>	-4,904	< 0,01

P-value uji Dickey-Fuller pada Tabel 4.3 sudah kurang dari taraf signifikansi. Hal ini mengindikasikan bahwa dengan melakukan *differencing* data *trend* menjadi stasioner. Berikut ditampilkan PACF dari kelompok *trend*, *seasonality*, dan *noise* yang sudah stasioner.



Gambar 4.8 Plot PACF (a) *Differencing Trend* (b) *Noise* (c) *Seasonality* (d) *Differencing Seasonality Skenario Pertama*


Berdasarkan Gambar 4.8 variabel *input* yang dipilih yaitu untuk *trend* yaitu *lag*-1 (T_{t-1}), *lag*-2 (T_{t-2}) dan *lag*-3 (T_{t-3}). Variabel *input* untuk *noise* yaitu *lag*-1 (N_{t-1}^*), *lag*-5 (N_{t-5}^*) dan *lag*-3 (N_{t-3}^*). Untuk kelompok *trend* dan *noise*, jika jumlah *input* yang digunakan satu maka diambil *lag* dengan signifikansi tertinggi, jika digunakan dua *input* maka diambil dua *lag* dengan signifikansi tertinggi, dan jika digunakan tiga *input* maka diambil tiga *lag* dengan signifikansi tertinggi. Variabel *input* untuk *seasonality* juga ditentukan berdasarkan plot PACF musiman yang ditunjukkan oleh Gambar 4.8 (d). *Lag* dengan signifikansi tertinggi Gambar 4.8 (c) adalah *lag*-10 sedangkan pada Gambar 4.8 (d) *lag*-9 sehingga variabel *input* untuk *seasonality* satu variabel *input* yaitu S_{t-10} , dua *input* yaitu dengan menambah efek *seasonality*nya, S_{t-10} dan S_{t-21} . Jika dikehendaki 3 *input* maka variabel *input* *seasonality* yaitu S_{t-10} , S_{t-21} dan S_{t-31} . Jenis fungsi keanggotaan yang digunakan pada skenario pertama ini adalah *Trapezoidal*, *Gaussian*, *Phi* dan *Generalize Bell*. Banyaknya fungsi keanggotaan yang digunakan yaitu dua dimana pembentukan *cluster* menggunakan *grid partition*.

Peramalan dengan metode ANFIS dilakukan pada masing-masing kombinasi jenis fungsi keanggotaan dan jumlah variabel *input*. Pemilihan model terbaik dapat dilihat berdasarkan kriteria RMSE *out-sample* yang dapat disajikan dalam Tabel 4.4.

Tabel 4.4 Perbandingan RMSE *Out-Sample* Kelompok *Trend*, *Seasonality*, dan *Noise* pada Skenario Pertama

Kelompok	Jenis Fungsi Keanggotaan	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	0,203	0,208	0,213
	<i>Gaussian</i>	0,435	0,609	1,060
	<i>Phi</i>	0,207	0,198	0,235
	<i>Generalized Bell</i>	0,377	0,569	1,342
<i>Seasonality</i>	<i>Trapezoidal</i>	10,028	10,657	8,146
	<i>Gaussian</i>	9,848	10,432	32,235
	<i>Phi</i>	10,132	10,137	29,577
	<i>Generalized Bell</i>	9,936	10,415	18,073
<i>Noise</i>	<i>Trapezoidal</i>	9,090	5,949	6,739
	<i>Gaussian</i>	9,028	5,878	9,483
	<i>Phi</i>	9,157	5,959	6,151
	<i>Generalized Bell</i>	9,073	6,047	7,514

Model ANFIS untuk kelompok *trend* pada skenario pertama yang paling baik berdasarkan nilai RMSE *out-sample* terkecil yang pada Tabel 4.4 dicetak dengan huruf tebal yaitu ANFIS dengan fungsi keanggotaan *Phi* 2 *input*. Pada kelompok *seasonality* model ANFIS dengan fungsi keanggotaan *Trapezoidal* 3 *input* dipilih sebagai model terbaik sedangkan model ANFIS terbaik untuk kelompok *noise* yaitu model dengan fungsi keanggotaan *Gaussian* 2 *input*. Model-model terbaik inilah yang digunakan untuk meramalkan 36 tahap ke depan pada tiap kelompok (sesuai dengan data *out-sample* yang digunakan). Berikut disajikan plot hasil ramalan SSA-ANFIS secara individu pada skenario pertama.



Gambar 4.9 Plot Hasil Ramalan Agregat SSA-ANFIS Skenario Pertama
(a) *Trend* (b) *Seasonality* (c) *Noise* (d) *Total*

Hasil ramalan metode ANFIS ditunjukkan oleh plot warna merah pada Gambar 4.9 sedangkan data aktual ditunjukkan dengan plot warna biru. Garis putus-putus merah merupakan batas antara data *in-sample* dan *out-sample*. Indeks pada sumbu x di atas merupakan periode dari data. Hasil ramalan masing-masing kelompok mengikuti pola data *out-sample* kecuali untuk kelompok *seasonality* yang pada beberapa periode ramalan awal mengikuti data dan selanjutnya tidak, namun secara umum dapat dikatakan jika metode ANFIS cukup baik dalam peramalan setiap kelompok pada skenario pertama ini.

b. Peramalan Individu

Penentuan variabel *input* dengan melihat plot PACF digunakan baik pada peramalan individu maupun agregat. Pada peramalan individu, variabel *input* ANFIS ditentukan untuk masing-masing *eigentruple* yang akan diramalkan. Pengujian stasioneritas tiap *eigentruple* disajikan dalam Tabel 4.5.

Tabel 4.5 Uji Dickey-Fuller Tiap *Eigentriple* Skenario Pertama


<i>Eigentriple</i>	Dickey-Fuller	<i>P-value</i>	Keterangan
1	-1,058	0,93	Tidak Stasioner
2	-1,379	0,84	Tidak Stasioner
3	-0,404	0,99	Tidak Stasioner
4	-3,775	0,02	Stasioner
5	-8,912	< 0,01	Stasioner
6	-2,633	0,31	Tidak Stasioner
7	2,797	> 0,99	Tidak Stasioner
8	-0,956	0,94	Tidak Stasioner
9	-5,094	< 0,01	Stasioner
10	-4,784	< 0,01	Stasioner
11	-4,736	< 0,01	Stasioner
<i>Noise</i>	-5,559	< 0,01	Stasioner

Perlu diketahui bahwa *eigentriple noise* pada peramalan individu berbeda dengan peramalan agregat, karena pada peramalan agregat *eigentriple* utama yang tidak termasuk *trend* dan *seasonality* dikelompokkan dalam *noise*, namun pada peramalan individu *noise* adalah keseluruhan *eigentriple* selain *eigentriple* utama. Tabel 4.5 menunjukkan bahwa *eigentriple* 1, 2, 3, 4, 7, dan *eigentriple* 8 belum stasioner karena *p-value* uji Dickey-Fuller kurang dari taraf signifikansi 0,05. Metode yang dapat dilakukan untuk menjadikan *eigentriple* tersebut menjadi stasioner yaitu *differencing* pada masing-masing *eigentriple* yang belum stasioner. Hasil uji Dickey-Fuller pada hasil *differencing* masing-masing *eigentriple* dapat dilihat pada Tabel 4.6.


Tabel 4.6 Uji Dickey-Fuller Hasil *Differencing Eigentriple* Skenario Pertama

<i>Eigentriple</i>	Dickey-Fuller	<i>P-value</i>	Keterangan
1	-5,380	< 0,01	Stasioner
2	-6,677	< 0,01	Stasioner
3	-12,088	< 0,01	Stasioner
6	-6,089	< 0,01	Stasioner
7	-12,456	< 0,01	Stasioner
8	-4,571	< 0,01	Stasioner

Setelah dilakukan *differencing*, dapat ditunjukkan pada Tabel 4.6 *p-value* uji Dickey-Fuller kurang dari taraf signifikansi 0,05 sehingga seluruh *eigentriple* sudah stasioner. Selanjutnya disajikan plot PACF dari tiap *eigentriple* yang sudah stasioner seperti pada Gambar 4.10.



Gambar 4.10 Plot PACF *Eigentriple* 1, 2, 3, ..., 11 dan Noise Skenario Pertama



Gambar 4.10 Plot PACF *Eigentriple* 1, 2, 3, ..., 11 dan *Noise* Skenario Pertama (Lanjutan)

Gambar 4.10 menunjukkan variabel *input* untuk masing-masing *eigentriple* dengan melihat *lag* PACF yang signifikan. Jika digunakan satu *input* maka dipilih *lag* PACF dengan signifikansi tertinggi, jika digunakan dua *input* maka dipilih dua *lag* dengan signifikansi tertinggi, sedangkan jika digunakan tiga *input* maka dipilih tiga *lag* dengan signifikansi tertinggi. Misal

deret ke- t pada tiap *eigentruple* utama didefinisikan sebagai X_t , dan deret *noise* ke t didefinisikan sebagai N_t^* , berikut disajikan tabel variabel *input* yang teridentifikasi untuk masing-masing *eigentruple* pada skenario pertama.

Tabel 4.7 Variabel *Input* Setiap *Eigentruple* pada Skenario Pertama

<i>Eigentruple</i>	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
1	X_{t-1}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-3}
2	X_{t-2}	X_{t-1} dan X_{t-2}	-
3	X_{t-2}	X_{t-1} dan X_{t-2}	-
4	X_{t-2}	X_{t-2} dan X_{t-3}	X_{t-2} , X_{t-3} dan X_{t-4}
5	X_{t-2}	X_{t-2} dan X_{t-4}	-
6	X_{t-2}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-4}
7	X_{t-4}	X_{t-1} dan X_{t-4}	X_{t-1} , X_{t-2} dan X_{t-4}
8	X_{t-2}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-3}
9	X_{t-2}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-3}
10	X_{t-2}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-3}
11	X_{t-1}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-3}
<i>Noise</i>	N_t^*	N_{t-10}^* dan N_{t-13}^*	N_{t-10}^* , N_{t-13}^* dan N_{t-25}^*

Pemodelan ANFIS dilakukan pada setiap *eigentruple* menggunakan variabel *input* seperti Tabel 4.7 di atas. Pemilihan model ANFIS terbaik didasarkan pada nilai RMSE *out-sample* tiap kombinasi jenis fungsi keanggotaan dan jumlah variabel *input*. Fungsi keanggotaan yang digunakan yaitu *Trapezoidal*, *Gaussian*, *Phi* dan *Generalized Bell*. Hasil perbandingan RMSE *out-sample* tiap kombinasi disajikan dalam Tabel 4.8 berikut.

Tabel 4.8 Perbandingan RMSE *Out-Sample* Setiap *Eigentriple* pada Skenario Pertama


<i>Eigentriple</i>	Fungsi Keanggotaan	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>	<i>Eigentriple</i>	Fungsi Keanggotaan	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
1	<i>Trapezoidal</i>	0,203	0,208	0,213	7	<i>Trapezoidal</i>	3,315	1,057	1,107
	<i>Gaussian</i>	0,435	0,609	1,060		<i>Gaussian</i>	3,316	1,091	1,391
	<i>Phi</i>	0,207	0,198	0,235		<i>Phi</i>	3,328	1,041	1,036
	<i>Generalized Bell</i>	0,377	0,569	1,342		<i>Generalized Bell</i>	3,323	1,067	2,901
2	<i>Trapezoidal</i>	4,205	0,733	-	8	<i>Trapezoidal</i>	2,243	0,263	0,273
	<i>Gaussian</i>	4,203	0,714	-		<i>Gaussian</i>	2,239	0,260	0,287
	<i>Phi</i>	4,206	0,772	-		<i>Phi</i>	2,242	0,271	0,283
	<i>Generalized Bell</i>	4,205	0,777	-		<i>Generalized Bell</i>	2,247	0,265	0,276
3	<i>Trapezoidal</i>	3,610	0,685	0,637	9	<i>Trapezoidal</i>	1,963	0,588	0,511
	<i>Gaussian</i>	3,609	0,709	0,630		<i>Gaussian</i>	1,963	0,541	0,500
	<i>Phi</i>	3,610	0,680	0,635		<i>Phi</i>	1,964	0,567	0,518
	<i>Generalized Bell</i>	3,609	0,689	0,630		<i>Generalized Bell</i>	1,964	0,579	0,501
4	<i>Trapezoidal</i>	3,057	0,875	0,874	10	<i>Trapezoidal</i>	1,077	0,458	0,359
	<i>Gaussian</i>	3,116	0,869	0,882		<i>Gaussian</i>	1,079	0,575	0,405
	<i>Phi</i>	3,117	0,925	0,888		<i>Phi</i>	1,078	0,531	0,454
	<i>Generalized Bell</i>	3,115	0,867	0,879		<i>Generalized Bell</i>	1,079	0,496	0,351
5	<i>Trapezoidal</i>	2,533	0,889	-	11	<i>Trapezoidal</i>	1,442	0,251	0,300
	<i>Gaussian</i>	2,530	0,521	-		<i>Gaussian</i>	1,444	0,279	0,276
	<i>Phi</i>	2,571	0,832	-		<i>Phi</i>	1,455	0,269	0,492
	<i>Generalized Bell</i>	2,542	0,530	-		<i>Generalized Bell</i>	1,444	0,278	0,274
6	<i>Trapezoidal</i>	4,569	2,446	1,087	<i>Noise</i>	<i>Trapezoidal</i>	3,881	4,037	4,327
	<i>Gaussian</i>	4,569	1,907	93,855		<i>Gaussian</i>	3,872	4,115	4,583
	<i>Phi</i>	4,562	2,425	2,051		<i>Phi</i>	3,932	4,069	4,721
	<i>Generalized Bell</i>	4,565	2,340	2,005		<i>Generalized Bell</i>	3,912	4,135	4,899

Nilai RMSE *out-sample* terkecil dicetak dengan huruf tebal pada Tabel 4.8. Dengan demikian model ANFIS terbaik pada masing-masing *eigentruple* yaitu model ANFIS dengan jenis fungsi keanggotaan dan variabel *input* seperti dalam Tabel 4.9.

Tabel 4.9 Model ANFIS Terbaik Setiap *Eigentruple* pada Skenario Pertama

<i>Eigentruple</i>	Jenis Fungsi Keanggotaan	Variabel <i>Input</i>
1	<i>Phi</i>	X_{t-1} dan X_{t-2}
2	<i>Gaussian</i>	X_{t-1} dan X_{t-2}
3	<i>Gaussian</i>	X_{t-2} , X_{t-3} dan X_{t-4}
4	<i>Generalized Bell</i>	X_{t-2} dan X_{t-4}
5	<i>Gaussian</i>	X_{t-2}
6	<i>Trapezoidal</i>	X_{t-1} , X_{t-2} dan X_{t-4}
7	<i>Phi</i>	X_{t-1} , X_{t-2} dan X_{t-4}
8	<i>Gaussian</i>	X_{t-1} dan X_{t-2}
9	<i>Gaussian</i>	X_{t-1} , X_{t-2} dan X_{t-3}
10	<i>Generalized Bell</i>	X_{t-1} , X_{t-2} dan X_{t-3}
11	<i>Trapezoidal</i>	X_{t-1} dan X_{t-2}
Noise	<i>Gaussian</i>	N_{t-13}^*

Hasil peramalan SSA-ANFIS individu didapatkan dengan menjumlahkan hasil ramalan ke-11 *eigentruple* ditambah dengan *eigentruple* noise yang dapat divisualisasikan dalam Gambar 4.11.



Gambar 4.11 Hasil Ramalan SSA-ANFIS Individu Skenario Pertama

Gambar 4.11 secara keseluruhan menunjukkan data skenario pertama serta hasil ramalan SSA-ANFIS individu pada data *out-sampelenya*. Data skenario pertama ditunjukkan oleh plot warna biru sedangkan hasil ramalan SSA-ANFIS individu ditunjukkan oleh plot warna merah. Garis merah putus-putus yang ada pada gambar merupakan batas antara data *in-sample* dan data *out-sample* skenario pertama. Pada Gambar 4.11 terlihat bahwa hasil ramalan SSA-ANFIS secara individu pada skenario pertama dapat mengikuti pola data *out-sample* dengan baik.


c. Perbandingan Hasil Ramalan SSA-ANFIS

Hasil ramalan keseluruhan untuk metode SSA-ANFIS didapatkan dengan menjumlahkan ramalan tiap dekomposisi. Hasil ramalan pada peramalan agregat didapatkan dengan menjumlahkan hasil ramalan *trend*, *seasonality* dan *noise*, sedangkan pada peramalan individu didapatkan dengan menjumlahkan hasil ramalan tiap *eigentriple*. Selanjutnya dilakukan evaluasi hasil ramalan tersebut menggunakan kriteria RMSE, MAPE, sMAPE, dan sMdAPE *out-sample* yang hasilnya dapat dilihat pada Tabel 4.10.

Tabel 4.10 Pemilihan Model ANFIS Setiap *Eigentriple* pada Skenario Pertama

Jenis Peramalan	RMSE	MAPE	sMAPE	sMdAPE
Agregat	6,039	7,759	7,857	7,782
Individu	6,427	8,004	7,927	8,045

Perbandingan hasil peramalan individu dan agregat pada skenario pertama dapat dilihat pada Tabel 4.10. Kesimpulan yang dapat diambil yaitu peramalan agregat memiliki peforma yang lebih baik jika dibandingkan dengan peramalan individu. Hal ini didasarkan pada nilai RMSE, MAPE, sMAPE, dan sMdAPE yang lebih kecil. Plot hasil ramalan keduanya ditampilkan dalam Gambar 4.12.




Gambar 4.12 Plot Perbandingan Hasil Ramalan Skenario Pertama

Gambar 4.12 menyajikan visualisasi perbandingan hasil ramalan metode SSA-ANFIS. Data *out-sample* atau data aktual ditunjukkan oleh plot berwarna hijau. Hasil ramalan agregat SSA-ANFIS ditunjukkan dengan plot berwarna merah sedangkan hasil ramalan individu SSA-ANFIS ditunjukkan oleh plot berwarna biru. Informasi yang diperoleh dari Gambar 4.12 yaitu hasil ramalan agregat lebih dekat dengan data aktual. Hal ini sesuai dengan pernyataan bahwa performa SSA-ANFIS agregat lebih baik dari individu berdasarkan nilai kriteria evaluasi model yang lebih kecil. Kesimpulan yang dapat diambil pada skenario pertama ini adalah peramalan agregat lebih baik dari peramalan individu metode SSA-ANFIS.

4.1.2 Skenario Kedua

Data simulasi yang digunakan pada skenario kedua yaitu data dengan variasi kalender, pola data *trend* dan musiman serta memiliki *noise* tidak *random* yaitu *noise* yang mengikuti pola AR(1). Data simulasi dalam skenario kedua ini dapat divisualisasi ke dalam Gambar 4.13.




Gambar 4.13 Time Series Plot Skenario Kedua

Berdasarkan Gambar 4.13 diketahui bahwa pola *trend* menyebabkan pertambahan data seiring dengan bertambahnya waktu. Pola musiman menggambarkan perulangan pola setiap 12 bulan. Kemudian efek variasi kalender memperlihatkan kejadian khusus pada bulan-bulan tertentu dimana kejadian khusus yang digunakan dalam simulasi ini adalah hari raya Idul Fitri.

Prosedur SSA-ANFIS diterapkan pada data simulasi skenario kedua ini. Parameter *window length* (L) yang digunakan yaitu 85 dengan perhitungan $L=(N+1)/2=(168+1)/2=84,5\approx 85$ sehingga didapatkan matriks lintasan \mathbf{X} .


$$\mathbf{X} = (x_{ij})_{i,j=1}^{85,84} = \begin{bmatrix} 18,162 & 21,914 & \cdots & 39,457 \\ 21,914 & 22,730 & \cdots & 41,015 \\ \vdots & \vdots & \ddots & \vdots \\ 41,015 & 44,745 & \cdots & 65,562 \end{bmatrix}$$

Matriks lintasan \mathbf{X} berisi data yang digunakan pada skenario kedua. Setelah didapatkan matriks tersebut didekomposisi menjadi 50 *eigentruple*. Nilai singular dari 50 *eigentruple* dapat dilihat pada Gambar 4.14.



Gambar 4.14 Plot Nilai Singular Skenario Kedua

Pengelompokan *eigentriple* dapat dilakukan dengan melihat Gambar 4.14. *Eigentriple* yang termasuk kelompok *noise* dapat ditandai dengan pola nilai singular yang menurun secara lambat seperti *eigentriple* 12, *eigentriple* 13 sampai dengan *eigentriple* 50. 11 *eigentriple* awal selain kelompok *noise* disebut sebagai *eigentriple* utama. *Eigentriple* utama selanjutnya akan dikelompokkan ke dalam kelompok *trend* dan *seasonality*. Pengelompokan *trend* dan *seasonality* dapat dilakukan dengan melihat plot ke-11 *eigentriple* seperti yang disajikan dalam Gambar 4.15.



Gambar 4.15 Plot *Eigentriple* Utama pada Skenario Kedua


Eigentruple 1 merupakan kelompok *trend* karena memiliki pola variasi yang lambat jika dilihat pada Gambar 4.15. Pengelompokan *eigentruple* ke dalam kelompok *seasonality* perlu mempertimbangkan periode musiman yang terbentuk dari pasangan *eigentruple*. Berikut disajikan tabel pengelompokan *eigentruple* utama beserta periode musiman yang terbentuk.

Tabel 4.11 Pengelompokan *Eigentruple* Skenario Kedua

<i>Eigentruple</i>	Periode (Bulan)
1	-
2	6
3	6
4	4
5	4
6	11
7	11
8	3
9	3
10	2
11	2

Eigentruple yang termasuk kelompok *seasonality* yaitu *eigentruple* yang memiliki pola variasi musiman serta memiliki periode musiman yang sesuai dengan musiman bulanan. Hasil pengelompokan *seasonality* sesuai dengan Tabel 4.11 yaitu *eigentruple* 2, *eigentruple* 3, *eigentruple* 4, *eigentruple* 5, *eigentruple* 8, *eigentruple* 9, *eigentruple* 10, dan *eigentruple* 11 karena memiliki periode musiman bulanan yang sama. Periode 11 bulan yang dibentuk *eigentruple* 6 dan *eigentruple* 7 tidak dapat diaplikasikan pada data bulanan sehingga keduanya dikelompokkan ke dalam kelompok *noise*. Dengan demikian *eigentruple* yang termasuk kelompok *noise* menjadi *eigentruple* 6, *eigentruple* 7, *eigentruple* 12, *eigentruple* 13 dan seterusnya sampai

eigentruple 50. Hasil rekonstruksi kelompok *trend*, *seasonality* dan *noise* dapat dilihat pada Gambar 4.16.



Gambar 4.16 Plot Hasil Rekonstruksi (a) *Trend* (b) *Seasonality* (c) *Noise* pada Skenario Kedua

Selanjutnya dilakukan tahap peramalan ANFIS pada hasil dekomposisi SSA baik peramalan individu maupun peramalan agregat.


a. Peramalan Agregat

Pemilihan variabel *input* pada peramalan agregat sama seperti skenario pertama yaitu berdasarkan *lag* PACF data stasioner yang signifikan. Pengujian stasioneritas data tiap kelompok pada skenario kedua melalui uji Dickey-Fuller disajikan dalam Tabel 4.12.

Tabel 4.12 Uji Dickey-Fuller pada Data Skenario Kedua

Kelompok	Dickey-Fuller	<i>P-value</i>	Keterangan
<i>Trend</i>	-0,971	0,94	Tidak Stasioner
<i>Differencing Trend</i>	-5,076	< 0,01	Stasioner
<i>Seasonality</i>	-23,320	< 0,01	Stasioner
<i>Noise</i>	-10,640	< 0,01	Stasioner

Berikutnya ditampilkan PACF dari kelompok *trend*, *seasonality* dan *noise* yang sudah stasioner.



Gambar 4.17 Plot PACF (a) *Differencing Trend* (b) *Noise* (c) *Seasonality* (d) *Differencing Seasonality* Skenario Kedua


Gambar 4.17 menunjukkan bahwa *lag* yang signifikan untuk kelompok *trend* yaitu *lag*-1, *lag*-2 dan *lag*-3 sehingga variabel *input* untuk *trend* adalah $lag-1(T_{t-1})$, $lag-2(T_{t-2})$, dan $lag-1(T_{t-3})$. Kelompok *noise* memiliki variabel *input* $lag-1(N_{t-1}^*)$, $lag-5(N_{t-5}^*)$ dan $lag-13(N_{t-13}^*)$. *Lag* signifikansi tertinggi pada plot PACF *seasonality* yaitu *lag*-10 dan pada plot *differencing* musimannya yaitu *lag*-9. Berdasarkan *lag* tersebut, variabel *input* untuk *seasonality* satu *input* yaitu S_{t-10} , dua *input* yaitu S_{t-10} dan S_{t-21} , serta tiga *input* yaitu S_{t-10} , S_{t-21} dan S_{t-31} . Jumlah fungsi keanggotaan yang digunakan adalah dua dengan jenis fungsi *Trapezoidal*, *Gaussian*, *Phi* dan *Generalize Bell*. Tabel 4.13 merupakan tabel perbandingan nilai RMSE *out-sample* untuk masing-masing kombinasi fungsi keanggotaan dan variabel *input*.

Tabel 4.13 Perbandingan RMSE *Out-Sample* Kelompok *Trend*, *Seasonality*, dan *Noise* pada Skenario Kedua

Kelompok	Jenis Fungsi Keanggotaan	1 Input	2 Input	3 Input
<i>Trend</i>	<i>Trapezoidal</i>	0,207	0,204	0,275
	<i>Gaussian</i>	0,473	0,283	1,249
	<i>Phi</i>	0,207	0,244	0,308
	<i>Generalized Bell</i>	0,441	0,755	1,535
<i>Seasonality</i>	<i>Trapezoidal</i>	9,996	10,744	8,031
	<i>Gaussian</i>	9,835	10,605	5,095
	<i>Phi</i>	10,122	10,054	87,793
	<i>Generalized Bell</i>	9,921	10,597	11,250
<i>Noise</i>	<i>Trapezoidal</i>	9,109	5,517	6,560
	<i>Gaussian</i>	9,032	5,623	7,174
	<i>Phi</i>	9,148	5,291	5,149
	<i>Generalized Bell</i>	9,067	5,667	6,767

Mengacu pada Tabel 4.13, model ANFIS terbaik untuk kelompok *trend* pada skenario kedua yaitu ANFIS fungsi keanggotaan *Trapezoidal* dengan 2 *input*. Model ANFIS kelompok *seasonality* yang dipilih yaitu model fungsi

keanggotaan *Gaussian* dengan 3 *input* sedangkan kelompok *noise* yaitu model ANFIS fungsi keanggotaan *Phi* dengan 3 *input*. Model terbaik tersebut dipilih berdasarkan nilai RMSE *out-sample* yang terkecil dan pada Tabel 4.13 nilai tersebut dicetak tebal. Hasil ramalan SSA-ANFIS agregat untuk kelompok *trend*, *seasonality*, dan *noise* serta hasil ramalan keseluruhan data pada skenario kedua ditampilkan dalam Gambar 4.18.



Gambar 4.18 Plot Hasil Ramalan Agregat SSA-ANFIS Skenario Kedua
(a) *Trend* (b) *Seasonality* (c) *Noise* (d) *Total*

Gambar 4.18 memberikan informasi bahwa peramalan SSA-ANFIS pada skenario kedua bekerja cukup baik karena hasil ramalan sudah mengikuti pola data aktual dengan baik walaupun pada kelompok *noise* masih terdapat beberapa kesalahan. Kesalahan-kesalahan yang terjadi dapat disebabkan karena pemilihan variabel *input* yang kurang optimal serta peramalan yang dilakukan merupakan peramalan 36 tahap ke depan, bukan peramalan satu tahap ke depan sehingga kemungkinan terjadi kesalahan cukup besar.

b. Peramalan Individu

Penentuan variabel *input* dengan melihat plot PACF data stasioner digunakan baik pada peramalan individu maupun agregat. Pada peramalan individu, variabel *input* ANFIS ditentukan untuk masing-masing *eigentruple* yang akan diramalkan. Sebelum membentuk plot PACF, dilakukan uji stasioneritas masing-masing *eigentruple* seperti pada Tabel 4.14.

Tabel 4.14 Uji Dickey-Fuller Setiap *Eigentruple* pada Skenario Kedua


<i>Eigentruple</i>	Dickey-Fuller	<i>P-value</i>	Keterangan
1	-0,971	0,94	Tidak Stasioner
2	-1,105	0,92	Tidak Stasioner
3	-0,815	0,96	Tidak Stasioner
4	-3,992	0,01	Stasioner
5	-8,055	< 0,01	Stasioner
6	-2,352	0,43	Tidak Stasioner
7	2,728	> 0,99	Tidak Stasioner
8	-0,191	> 0,99	Tidak Stasioner
9	-4,830	< 0,01	Stasioner
10	-4,600	< 0,01	Stasioner
11	-5,076	< 0,01	Stasioner
Noise	-5,529	< 0,01	Stasioner

Berikutnya dilakukan *differencing* pada *eigentruple* yang tidak stasioner. Hasil uji stasioneritas pada data hasil *differencing* ditunjukkan oleh Tabel 4.15.


Tabel 4.15 Uji Dickey-Fuller Hasil *Differencing Eigentruple* Skenario Kedua

<i>Eigentruple</i>	Dickey-Fuller	<i>P-value</i>	Keterangan
1	-5,076	< 0,01	Stasioner
2	-6,097	< 0,01	Stasioner
3	-3,662	0,03	Stasioner
6	-9,645	< 0,01	Stasioner
7	-13,064	< 0,01	Stasioner
8	-4,909	< 0,01	Stasioner

Berdasarkan Tabel 4.15 seluruh *eigentriple* sudah stasioner karena p -value uji Dickey-Fuller kurang dari taraf signifikansi 0,05 sehingga dapat disajikan plot PACF dari masing-masing *eigentriple* yang sudah stasioner.



Gambar 4.19 Plot PACF *Eigentriple* 1, 2, 3, ..., 11 dan Noise Skenario Kedua



Gambar 4.19 Plot PACF *Eigentriple* 1, 2, 3, ..., 11 dan *Noise* Skenario Kedua (Lanjutan)

Variabel *input* untuk masing-masing *eigentriple* dengan melihat *lag* PACF yang signifikan pada Gambar 4.19 dapat disajikan seperti pada Tabel 4.16.

Tabel 4.16 Variabel *Input* Setiap *Eigentriple* pada Skenario Kedua


<i>Eigentriple</i>	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
1	X_{t-1}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-3}
2	X_{t-2}	X_{t-1} dan X_{t-2}	-
3	X_{t-2}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-3}
4	X_{t-2}	X_{t-2} dan X_{t-3}	X_{t-2} , X_{t-3} dan X_{t-4}
5	X_{t-2}	X_{t-2} dan X_{t-4}	-
6	X_{t-2}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-4}
7	X_{t-4}	X_{t-1} dan X_{t-4}	X_{t-1} , X_{t-2} dan X_{t-4}
8	X_{t-2}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-3}
9	X_{t-2}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-3}
10	X_{t-2}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-3}
11	X_{t-1}	X_{t-1} dan X_{t-2}	X_{t-1} , X_{t-2} dan X_{t-3}
<i>Noise</i>	N_{t-13}^*	N_{t-10}^* dan N_{t-13}^*	N_{t-10}^* , N_{t-13}^* dan N_{t-25}^*

Masing-masing variabel *input* pada Tabel 4.16 dimodelkan dengan ANFIS dengan fungsi keanggotaan *Trapezoidal*, *Gaussian*, *Phi* dan *Generalize Bell* sehingga tiap *eigentruple* mempunyai 12 pilihan model. Dari 12 model tersebut dipilih model terbaik berdasarkan kriteria RMSE *out-sample* yang dapat dilihat pada Lampiran 3. Model ANFIS terbaik untuk masing-masing *eigentruple* disajikan pada Tabel 4.17.

Tabel 4.17 Model ANFIS Terbaik Setiap *Eigentruple* pada Skenario Kedua

<i>Eigentruple</i>	Jenis Fungsi Keanggotaan	Variabel Input
1	<i>Trapezoidal</i>	X_{t-1} dan X_{t-2}
2	<i>Gaussian</i>	X_{t-1} dan X_{t-2}
3	<i>Generalized Bell</i>	X_{t-2} , X_{t-3} dan X_{t-3}
4	<i>Generalized Bell</i>	X_{t-2} dan X_{t-3}
5	<i>Gaussian</i>	X_{t-2} dan X_{t-4}
6	<i>Trapezoidal</i>	X_{t-1} , X_{t-2} dan X_{t-4}
7	<i>Phi</i>	X_{t-1} dan X_{t-4}
8	<i>Trapezoidal</i>	X_{t-1} dan X_{t-2}
9	<i>Generalized Bell</i>	X_{t-1} , X_{t-2} dan X_{t-3}
10	<i>Generalized Bell</i>	X_{t-1} , X_{t-2} dan X_{t-3}
11	<i>Trapezoidal</i>	X_{t-1} , X_{t-2} dan X_{t-3}
Noise	<i>Gaussian</i>	N^*_{t-13}

Selanjutnya ditunjukkan hasil ramalan SSA-ANFIS individu untuk data simulasi pada skenario kedua.



Gambar 4.20 Hasil Ramalan SSA-ANFIS Individu pada Skenario Kedua

Gambar 4.20 menunjukkan bahwa hasil ramalan *out-sample* untuk skenario kedua sudah mengikuti pola data aktualnya. Pola yang ditunjukkan juga tidak memiliki perbedaan yang jauh dengan skenario pertama.


c. Perbandingan Hasil Ramalan SSA-ANFIS

Evaluasi hasil ramalan SSA-ANFIS agregat dan individu terhadap data *out-sample* dapat dilihat pada tabel 4.18 berikut.

Tabel 4.18 Pemilihan Model ANFIS Setiap *Eigentriple* pada Skenario Kedua

Jenis Peramalan	RMSE	MAPE	sMAPE	sMdAPE
Agregat	4,709	6,053	6,122	5,676
Individu	5,232	6,256	6,135	5,283

Informasi yang dapat diberikan Tabel 4.18 yaitu peramalan agregat memiliki performa yang lebih baik karena nilai RMSE, MAPE, sMAPE, dan sMdAPE lebih kecil daripada peramalan individu. Selanjutnya disajikan perbandingan hasil ramalan SSA-ANFIS individu dan agregat terhadap data aktual.




Gambar 4.21 Plot Perbandingan Hasil Ramalan Skenario Kedua

Data aktual ditunjukkan oleh plot berwarna hijau pada Gambar 4.21. Hasil ramalan agregat SSA-ANFIS ditunjukkan dengan plot berwarna merah sedangkan hasil ramalan individu SSA-ANFIS ditunjukkan oleh plot berwarna biru. Plot hasil ramalan agregat lebih mendekati plot data aktual sehingga dapat disimpulkan bahwa pada skenario kedua, peramalan agregat lebih baik dari peramalan individu metode SSA-ANFIS.

Kesimpulan kajian simulasi secara umum yaitu metode peramalan agregat SSA-ANFIS menunjukkan performa yang lebih baik daripada metode peramalan individu untuk data dengan variasi kalender baik yang memiliki *noise random* maupun tidak *random*.

4.2 Karakteristik Data *Inflow* dan *Outflow* di Indonesia

Karakteristik dari data *inflow* dan *outflow* penting untuk diketahui sebelum melakukan analisis lebih lanjut. Berikut disajikan plot pola rata-rata per bulan dari data *inflow* dan *outflow* total di Indonesia pada tahun 2003 - 2016.




Gambar 4.22 Plot Pola *Inflow* dan *Outflow* di Indonesia


Gambar 4.22 memperlihatkan *inflow* dan *outflow* uang kartal kertas di Indonesia mengalami kenaikan dari tahun 2003 sampai 2006. Pada tahun 2007 *inflow* dan *outflow* uang kartal kertas mengalami penurunan namun kembali naik pada tahun

2008 hingga tahun 2016. Penurunan pada tahun 2007 disebabkan adanya suatu kebijakan Bank Indonesia terkait penyetoran dan penarikan uang. Informasi lain yang didapatkan dari plot di atas yaitu *outflow* selalu lebih besar dari *inflow* sepanjang tahun 2003-2016. Kondisi demikian mencerminkan bahwa jumlah uang kartal yang masuk ke Bank Indonesia lebih kecil dari jumlah yang dikeluarkan.

Selanjutnya disajikan *time series* plot dari masing-masing pecahan *inflow* dan *outflow* mulai pecahan Rp 100.000,00 sampai pecahan Rp 1.000,00 di Indonesia.




Gambar 4.23 Time Series Plot *Inflow* dan *Outflow* per Pecahan di Indonesia



Gambar 4.23 Time Series Plot *Inflow* dan *Outflow* per Pecahan di Indonesia (Lanjutan)

Gambar 4.23 memperlihatkan baik pola *inflow* maupun *outflow* mengalami kenaikan secara khusus pada garis biru yaitu bulan terjadinya hari raya Idul Fitri. Dapat dilihat bahwa pengaruh kebijakan Bank Indonesia terkait penarikan dan penyetoran uang pada pecahan *inflow* maupun *outflow* Rp 50.000,00 dan Rp 20.000,00 serta pecahan *outflow* Rp 100.000,00 yang mengalami penurunan cukup signifikan tahun 2007. Pecahan *inflow* dan *outflow* yang lain tidak menunjukkan pengaruh yang signifikan. Pecahan uang kartal Rp 1.000,00 terus mengalami penurunan baik *inflow* maupun *outflow*. Garis merah yang ditunjukkan pada Gambar 4.23 di atas merupakan garis batas antara data yang digunakan sebagai data *in-sample* dan data *out-sample*. Garis tersebut terletak pada titik 132,5 sehingga banyaknya data *in-sample* yang digunakan yaitu 132 data sedangkan data *out-sample* yang digunakan sebanyak 36 data.


Berikut ini disajikan perbandingan rata-rata *inflow* pada bulan saat terjadinya hari raya Idul Fitri dan satu bulan setelah terjadinya hari raya Idul Fitri berdasarkan minggu terjadinya hari raya Idul Fitri (minggu ke-1, 2, 3 atau 4).



Gambar 4.24 Rata-Rata *Inflow* pada Bulan Terjadi dan Satu Bulan Setelah Hari Raya Idul Fitri

Berdasarkan Gambar 4.24, diketahui bahwa perbedaan minggu terjadinya hari raya berpengaruh terhadap besarnya *inflow* pada bulan tersebut. Hari raya Idul Fitri yang terjadi pada minggu ke-1, 2 atau 3 menyebabkan peningkatan *inflow* yang signifikan pada bulan tersebut. Jika hari raya Idul Fitri terjadi pada minggu ke-4 maka terjadi peningkatan *inflow* yang signifikan pada akhir bulan berikutnya.

Hasil analisis yang serupa untuk data *outflow* disajikan pada Gambar 4.25.



Gambar 4.25 Rata-Rata *Outflow* pada Bulan Terjadi dan Satu Bulan Setelah Hari Raya Idul Fitri

Berbeda dengan data *inflow*, dapat dilihat pada Gambar 4.25 jika hari raya Idul Fitri yang terjadi pada minggu ke-1, 2 atau 3 maka peningkatan *inflow* yang signifikan terjadi satu bulan setelahnya sedangkan jika hari raya Idul Fitri terjadi pada minggu ke-4 maka peningkatan *inflow* yang signifikan terjadi pada bulan tersebut. Hal ini mengindikasikan bahwa perbedaan minggu terjadinya hari raya Idul Fitri juga mempengaruhi perbedaan besarnya kenaikan *outflow*. Dengan demikian, terjadinya hari raya Idul Fitri yang pada minggu yang berbeda akan mengakibatkan perbedaan peningkatan *inflow* dan *outflow*.

Kemudian ditunjukkan statistika deskriptif dari data *inflow* dan *outflow* tiap pecahan.

Tabel 4.19 Statistika Deskriptif Data *Inflow* (miliar Rp)

Data	Pecahan	Mean	St.dev	Minimum	Maksimum
<i>Inflow</i>	100.000	12549,0	10836,0	2315,0	68367,0
	50.000	12382,0	5725,0	3538,0	37083,0
	20.000	946,2	486,1	399,6	2776,5
	10.000	573,3	252,0	235,6	1908,7
	5.000	418,0	204,0	164,7	1589,3
	2.000	202,3	114,8	3,8	508,0
	1.000	95,0	70,1	10,6	292,7

Tabel 4.20 Statistika Deskriptif Data *Outflow* (miliar Rp)

Data	Pecahan	Mean	St.dev	Minimum	Maksimum
<i>Outflow</i>	100.000	14650,0	12827,0	1755,0	81487,0
	50.000	13013,0	7027,0	1934,0	40925,0
	20.000	969,4	751,8	106,2	5017,8
	10.000	624,2	624,4	89,2	4378,0
	5.000	464,6	592,2	64,6	4262,6
	2.000	276,2	383,9	0,1	1792,5
	1.000	91,1	100,7	1,7	496,4

Seperti yang disajikan dalam Tabel 4.19 dan Tabel 4.20, rata-rata (*mean*) dan standar deviasi *inflow* maupun *outflow* uang pecahan Rp 100.000,00 merupakan rata-rata dan standar deviasi terbesar dari seluruh pecahan sedangkan yang terkecil pada pecahan Rp 1.000,00. Dapat dilihat pola rata-rata maupun standar deviasi dari pecahan Rp 100.000,00, Rp 50.000,00, Rp 20.000,00, Rp 10.000,00, Rp 5.000,00, Rp 2.000,00 dan Rp 1.000,00 baik *inflow* maupun *outflow* terus menurun. Hal ini dikarenakan *range* dan jumlah nominal pecahan Rp 100.000,00 lebih besar dari pecahan Rp 50.000,00, *range* dan nominal pecahan Rp 50.000,00 lebih besar dari pecahan Rp 20.000,00, *range* dan nominal pecahan Rp 20.000,00 lebih besar dari pecahan Rp 10.000,00 dan seterusnya sehingga terbentuk pola menurun.

4.3 Pemodelan Data *Inflow* dan *Outflow* dengan ARIMAX

Sebelum dilakukan pemodelan, data *inflow* dan *outflow* uang kartal per pecahan dibagi ke dalam data *in-sample* dan data *out-sample* dimana data *out-sample* yang digunakan yaitu 36 data terakhir. Data *out-sample* ini nantinya digunakan untuk mengetahui performa model ARIMAX. Langkah awal pemodelan ARIMAX yaitu dengan menentukan variabel *dummy trend*, bulan, dan efek variasi kalender hari raya Idul Fitri. Pada bab 3 sebelumnya telah dilakukan identifikasi variabel *dummy* untuk efek variasi kalender hari raya Idul Fitri tahun 2003 sampai tahun 2016. Untuk data *inflow*, *dummy* variasi kalender yang digunakan

yaitu bulan terjadi Idul Fitri ($V_{j,t}$) dan satu bulan setelah hari raya Idul Fitri ($V_{j,t+1}$) sedangkan *dummy* variasi kalender yang digunakan pada data *outflow* yaitu bulan terjadi Idul Fitri ($V_{j,t}$) dan satu bulan sebelum hari raya Idul Fitri ($V_{j,t-1}$) dengan j adalah minggu terjadinya hari raya Idul Fitri.


Setelah menentukan variabel *dummy*, langkah selanjutnya yaitu melakukan regresi antara data *inflow* dan *outflow* per pecahan dengan variabel prediktor berupa variabel *dummy* yang telah dijelaskan. Dari hasil regresi tersebut dilakukan pemeriksaan apakah residual yang dihasilkan telah memenuhi asumsi *white noise* melalui *Ljung-box test*. Jika didapatkan hasil bahwa residual belum memenuhi asumsi *white noise*, maka dilakukan pemodelan ARIMA pada data. Sebaliknya jika residual sudah memenuhi asumsi *white noise* maka tidak perlu dilakukan pemodelan lebih lanjut. Tabel 4.21 menyajikan hasil *Ljung-box test* pada residual regresi tiap pecahan *inflow* dan *outflow*.

Tabel 4.21 *Ljung-Box Test* untuk Residual Regresi per Pecahan

<i>Inflow</i>	Hingga lag ke-	χ^2	<i>p-value</i>	<i>Outflow</i>	Hingga lag ke-	χ^2	<i>p-value</i>
Rp 100.000,00	12	305,02	<0,0001	Rp 100.000,00	12	212,11	<0,0001
	24	340,08	<0,0001		24	250,42	<0,0001
	36	353,09	<0,0001		36	259,66	<0,0001
Rp 50.000,00	12	542,84	<0,0001	Rp 50.000,00	12	310,35	<0,0001
	24	590,04	<0,0001		24	341,42	<0,0001
	36	682,90	<0,0001		36	378,20	<0,0001
Rp 20.000,00	12	697,17	<0,0001	Rp 20.000,00	12	313,24	<0,0001
	24	812,28	<0,0001		24	368,91	<0,0001
	36	937,51	<0,0001		36	425,25	<0,0001
Rp 10.000,00	12	439,52	<0,0001	Rp 10.000,00	12	24,45	0,0180
	24	500,23	<0,0001		24	39,87	0,0220
	36	541,30	<0,0001		36	60,26	0,0070
Rp 5.000,00	12	184,37	<0,0001	Rp 5.000,00	12	17,39	0,1360
	24	205,83	<0,0001		24	44,43	0,0070
	36	233,84	<0,0001		36	46,61	0,1110
Rp 2.000,00	12	109,63	<0,0001	Rp 2.000,00	12	12,33	0,4200
	24	117,49	<0,0001		24	18,41	0,7830
	36	160,15	<0,0001		36	23,86	0,9400
Rp 1.000,00	12	72,46	<0,0001	Rp 1.000,00	12	169,94	<0,0001
	24	86,06	<0,0001		24	169,52	<0,0001
	36	104,79	<0,0001		36	196,20	<0,0001


Tabel 4.21 memberikan informasi bahwa pecahan *outflow* Rp 2.000,00 sudah memenuhi asumsi *white noise* karena *p-value* lebih dari α ($\alpha=0,05$). Dengan demikian, model ARIMAX pada pecahan *outflow* Rp 2.000,00 yaitu model regresi *time series* yang sudah diperoleh. Residual regresi dari pecahan *inflow* dan *outflow* yang lain belum memenuhi asumsi *white noise* sehingga perlu dilakukan pemodelan ARIMA pada tiap pecahan tersebut.

Tahapan ARIMA prosedur Box-Jenkins diawali dengan tahap identifikasi orde p , q , dan r pada data yang sudah stasioner. Untuk mengetahui stasioneritas data dalam *mean* dapat dilihat melalui plot ACF. Plot ACF dari data *inflow* Rp 100.000,00 dapat dilihat pada Gambar 4.26.




Gambar 4.26 Plot ACF Pecahan *Inflow* Rp 100.000,00

Dari Gambar 4.26 diketahui bahwa pola ACF dari pecahan *inflow* Rp 100.000,00 turun lambat. Hal ini mengindikasikan bahwa data tersebut belum stasioner dalam *mean*. Untuk mengatasi ketidastasioneran data dalam *mean* dapat dilakukan *differencing* pada data. Gambar 4.27 dan 4.28 berikut merupakan plot ACF dan PACF dari pecahan *inflow* Rp 100.000,00 setelah *differencing lag-1*.



Gambar 4.27 Plot ACF Hasil Differencing Pecahan Inflow Rp 100.000,00



Gambar 4.28 Plot PACF Hasil Differencing Pecahan Inflow Rp 100.000,00

Orde ARIMAX pecahan inflow Rp 100.000,00 dapat dilihat melalui plot ACF dan PACF pada Gambar 4.27 dan 4.28 di atas. Berdasarkan gambar tersebut model dugaan ARIMAX yang didapatkan yaitu seperti pada Tabel 4.22.

Tabel 4.22 Pemilihan Model ARIMAX Pecahan *Inflow* Rp 100.000,00

Model	Residual		Parameter ARIMA Signifikan
	<i>White Noise</i>	Dist.Normal	
ARIMAX(0,1,[1,12,13,22,23])	Tidak	Tidak	Tidak
ARIMAX(0,1,[1,12,23])	Tidak	Tidak	Tidak
ARIMAX(0,1,[1,23])	Tidak	Tidak	Tidak
ARIMAX([23],1,[1,13])	Ya	Tidak	Ya

Model ARIMAX terbaik untuk pecahan *inflow* Rp 100.000,00 berdasarkan Tabel 4.22 adalah model ARIMA([23],1,[1,13]). Model dipilih karena residual dari model tersebut sudah memenuhi asumsi *white noise* dan parameter ARIMAny sudah signifikan. Berikut disajikan estimasi parameter model ARIMAX ([23],1,[1,13]).

Tabel 4.23 Estimasi Parameter Model ARIMAX Pecahan *Inflow* Rp 100.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA(1)	θ_1	0,792	0,094	8,40	<0,0001
MA([13])	θ_{13}	0,208	0,078	2,65	0,0080
AR([23])	ϕ_{23}	0,584	0,144	4,07	<0,0001
T_t^*	β	3,018	1,537	1,96	0,0496
$M_{1,t}$	γ_1	6838,300	1127,500	6,07	<0,0001
$M_{2,t}$	γ_2	-6254,700	1134,300	-5,51	<0,0001
$M_{3,t}$	γ_3	-584,421	1132,400	-0,52	0,6058
$M_{4,t}$	γ_4	-68,888	1128,400	-0,06	0,9513
$M_{5,t}$	γ_5	5,536	1126,200	0,00	0,9961
$M_{6,t}$	γ_6	-113,847	1127,300	-0,10	0,9196
$M_{7,t}$	γ_7	2156,300	1133,400	1,90	0,0571
$M_{8,t}$	γ_8	-531,924	1234,200	-0,43	0,6665
$M_{9,t}$	γ_9	-1959,500	1254,000	-1,56	0,1181
$M_{10,t}$	γ_{10}	-1836,000	1234,500	-1,49	0,1370
$M_{11,t}$	γ_{11}	-2630,000	1272,000	-2,07	0,0387
$M_{12,t}$	γ_{12}	-2428,900	1201,900	-2,02	0,0433
$V_{1,t}$	δ_1	13014,400	3093,800	4,21	<0,0001
$V_{2,t}$	δ_2	14323,600	2851,000	5,02	<0,0001
$V_{3,t}$	δ_3	7247,200	2393,400	3,03	0,0025
$V_{4,t}$	δ_4	3001,700	2019,400	1,49	0,1372
$V_{1,t+1}$	δ_5	-5915,800	2696,800	-2,19	0,0283
$V_{2,t+1}$	δ_6	-9444,100	2766,400	-3,41	0,0006
$V_{3,t+1}$	δ_7	-2061,100	2509,700	-0,82	0,4115
$V_{4,t+1}$	δ_8	4453,400	2653,800	1,68	0,0933

Dapat dilihat pada Tabel 4.23 bahwa parameter ARIMA sudah signifikan namun tidak semua parameter *time series regression* (TSR) signifikan. Untuk kepentingan peramalan, keseluruhan variabel tetap dimasukkan ke dalam model. *Syntax* ARIMAX keseluruhan untuk pecahan *inflow* Rp 100.000,00 dapat dilihat pada Lampiran 4.

Dengan prosedur yang sama, model ARIMAX terbaik untuk pecahan *inflow* dan *outflow* yang lain dapat disajikan dalam Tabel 4.24.

Tabel 4.24 Model ARIMA Terbaik Pecahan *Inflow* dan *Outflow*

Data	Pecahan	Model
<i>Inflow</i>	Rp 50.000,00	ARIMAX([1,12],1,[23])
	Rp 20.000,00	ARIMAX(0,1,1)(0,1,0) ¹²
	Rp 10.000,00	ARIMAX([11,12,23],1,1)
	Rp 5.000,00	ARIMAX([1,11,12,13],0,[23])
	Rp 2.000,00	ARIMAX([1,12],0,0)
	Rp 1.000,00	ARIMAX([1,11,12,23],1,1)
<i>Outflow</i>	Rp 100.000,00	ARIMAX([1,12,23],1,1)
	Rp 50.000,00	ARIMAX([23],1,[1,12,13])
	Rp 20.000,00	ARIMAX([1,12],1,[13])
	Rp 10.000,00	ARIMAX(0,0,[12,13])
	Rp 5.000,00	ARIMAX(0,0,[11,24])
	Rp 1.000,00	ARIMAX([12,23],1,[1,23])

Pemilihan model seperti pada Tabel 4.24 terlampir pada Lampiran 5 dan 6 yaitu lampiran identifikasi orde ARIMAX dan uji asumsi *white noise* dan distribusi normal dimana keseluruhan model merupakan model yang sudah memenuhi asumsi *white noise*. Estimasi parameter model ARIMAX pada pecahan *inflow* dan *outflow* lainnya dapat dilihat pada Lampiran 7. Selanjutnya disajikan model matematis ARIMAX untuk masing-masing pecahan *inflow* dan *outflow* uang kartal di Indonesia.

a. Model ARIMAX pecahan *inflow* Rp 100.000,00

$$\begin{aligned}
 Y_t = & 3,018T_t^* + 6838,300M_{1,t} - 6254,700M_{2,t} - 584,421M_{3,t} \\
 & - 68,888M_{4,t} + 5,536M_{5,t} - 113,847M_{6,t} + 2156,300M_{7,t} \\
 & - 531,924M_{8,t} - 1959,500M_{9,t} - 1836,000M_{10,t} - 2630,000M_{11,t} \\
 & - 2428,900M_{12,t} + 13014,400V_{1,t} + 14323,600V_{2,t} + 7247,200V_{3,t} \\
 & + 3001,700V_{4,t} - 5915,800V_{1,t+1} - 9444,100V_{2,t+1} - 2061,100V_{3,t+1} \\
 & + 4453,4V_{4,t+1} + \frac{1 - 0,792B - 0,208B^{13}}{(1 - 0,584B^{23})(1 - B)} a_t
 \end{aligned}$$

b. Model ARIMAX pecahan *inflow* Rp 50.000,00

$$\begin{aligned}
 Y_{2,t} = & -1,035T_t^* + 6575,800M_{1,t} - 5898,400M_{2,t} + 209,353M_{3,t} \\
 & - 243,326M_{4,t} - 366,477M_{5,t} + 237,686M_{6,t} + 2201,500M_{7,t} \\
 & - 505,418M_{8,t} - 1849,800M_{9,t} - 208,594M_{10,t} - 4147,400M_{11,t} \\
 & - 2303,200M_{12,t} + 14415,900V_{1,t} + 11708,600V_{2,t} + 6901,700V_{3,t} \\
 & + 1386,100V_{4,t} - 5061,100V_{1,t+1} - 5113,8V_{2,t+1} + 332,953V_{3,t+1} \\
 & + 9077,000V_{4,t+1} + \frac{1 + 0,582B^{23}}{(1 + 0,522B - 0,268B^{12})(1 - B)} a_t
 \end{aligned}$$

c. Model ARIMAX pecahan *inflow* Rp 20.000,00

$$\begin{aligned}
 Y_{3,t} = & 0,115T_t^* + 74,539M_{1,t} + 38,573M_{2,t} - 10,731M_{3,t} \\
 & - 11,950M_{4,t} + 6,601M_{5,t} - 25,975M_{6,t} - 21,458M_{7,t} \\
 & - 27,091M_{8,t} - 0,351M_{9,t} - 78,777M_{10,t} + 75,862M_{11,t} \\
 & - 101,749M_{12,t} + 432,121V_{1,t} + 307,494V_{2,t} + 367,694V_{3,t} \\
 & + 47,0316V_{4,t} - 462,269V_{1,t+1} - 249,0936V_{2,t+1} - 483,643V_{3,t+1} \\
 & - 145,044V_{4,t+1} + \frac{1 - 0,755B}{(1 - B)(1 - B^{12})} a_t
 \end{aligned}$$

d. Model ARIMAX pecahan *inflow* Rp 10.000,00

$$\begin{aligned}
 Y_{4,t} = & -0,03227T_t^* + 97,95123M_{1,t} - 130,21764M_{2,t} - 32,79478M_{3,t} \\
 & - 67,868M_{4,t} - 48,023M_{5,t} - 41,779M_{6,t} + 22,709M_{7,t} \\
 & - 18,965M_{8,t} - 31,383M_{9,t} - 108,902M_{10,t} - 140,226M_{11,t} \\
 & - 136,978M_{12,t} + 431,965V_{1,t} + 258,212V_{2,t} + 111,258V_{3,t} \\
 & - 9,878V_{4,t} + 162,994V_{1,t+1} + 378,688V_{2,t+1} + 502,134V_{3,t+1} \\
 & + 683,25V_{4,t+1} + \frac{1 - 0,600B}{(1 - B)(1 - 0,402B^{11} - 0,258B^{12} - 0,227B^{23})} a_t
 \end{aligned}$$

e. Model ARIMAX pecahan *inflow* Rp 5.000,00

$$\begin{aligned}
 Y_{5,t} = & 1,315T_t^* + 356,946M_{1,t} + 284,832M_{2,t} + 282,208M_{3,t} \\
 & + 241,990M_{4,t} + 213,915M_{5,t} + 201,667M_{6,t} + 232,909M_{7,t} \\
 & + 288,872M_{8,t} + 327,051M_{9,t} + 314,868M_{10,t} + 284,291M_{11,t} \\
 & + 261,114M_{12,t} + 138,542V_{1,t} - 13,9254V_{2,t} - 71,627V_{3,t} \\
 & - 111,672V_{4,t} + 175,773V_{1,t+1} + 122,066V_{2,t+1} + 115,312V_{3,t+1} \\
 & + 129,439V_{4,t+1} \\
 & + \frac{1 + 0,402B^{23}}{1 - 0,617B - 0,380B^{11} - 0,2444B^{12} + 40123,000B^{13}} a_t
 \end{aligned}$$

f. Model ARIMAX pecahan *inflow* Rp 2.000,00

$$\begin{aligned}
 Y_{6,t} = & 4,597T_t^* + 79,806M_{1,t} + 52,988M_{2,t} + 43,248M_{3,t} \\
 & + 16,257M_{4,t} + 1,34368M_{5,t} - 16,817M_{6,t} - 31,253M_{7,t} \\
 & + 32,046M_{8,t} + 158,469M_{9,t} + 160,125M_{10,t} \\
 & + 92,0447M_{11,t} + 61,560M_{12,t} - 101,810V_{2,t} - 107,683V_{3,t} \\
 & - 101,794V_{4,t} + 13,082V_{2,t+1} - 95,389V_{3,t+1} - 150,443V_{4,t+1} \\
 & + \frac{1}{1 - 0,815B + 0,192B^{12}} a_t
 \end{aligned}$$

g. Model ARIMAX pecahan *inflow* Rp 1.000,00

$$\begin{aligned}
 Y_{7,t} = & -0,027T_t^* + 24,850M_{1,t} - 8,198M_{2,t} + 0,546M_{3,t} \\
 & - 19,467M_{4,t} - 10,813M_{5,t} - 20,176M_{6,t} - 7,751M_{7,t} \\
 & - 2,375M_{8,t} - 16,254M_{9,t} + 4,962M_{10,t} + 22,375M_{11,t} \\
 & + 3,349M_{12,t} + 35,453V_{1,t} + 10,929V_{2,t} - 10,145V_{3,t} \\
 & - 28,090V_{4,t} + 25,590V_{1,t+1} + 40,103V_{2,t+1} + 71,530V_{3,t+1} \\
 & + 67,055V_{4,t+1} \\
 & + \frac{1 - 0,593B}{(1 - B)(1 + 0,186B - 0,168B^{11} - 0,540B^{12} - 0,331B^{23})} a_t
 \end{aligned}$$

h. Model ARIMAX pecahan *outflow* Rp 100.000,00

$$\begin{aligned}
 Y_{8,t} = & 1,988T_t^* - 17230,100M_{1,t} + 5274,000M_{2,t} + 1408,900M_{3,t} \\
 & + 1242,800M_{4,t} + 1422,300M_{5,t} + 386,633M_{6,t} - 883,590M_{7,t} \\
 & - 5802,800M_{8,t} - 1299,500M_{9,t} - 897,857M_{10,t} - 436,575M_{11,t} \\
 & - 5470,000M_{12,t} - 1476,600V_{1,t} + 10533,900V_{2,t} + 15552,900V_{3,t} \\
 & + 10212,9V_{4,t} + 12935,100V_{1,t+1} + 2466,000V_{2,t+1} - 5105,400V_{3,t+1} \\
 & + 310,68817V_{4,t+1} + \frac{1 - 0,703B}{(1 + 0,176B - 0,758B^{12} - 0,307B^{23})(1 - B)} a_t
 \end{aligned}$$

i. Model ARIMAX pecahan *outflow* Rp 50.000,00

$$\begin{aligned}
 Y_{9,t} = & -0,708T_t^* - 13807,200M_{1,t} + 1628,200M_{2,t} + 2401,200M_{3,t} \\
 & + 182,529M_{4,t} + 1001,6M_{5,t} + 1868,400M_{6,t} - 1357,100M_{7,t} \\
 & - 671,107M_{8,t} - 4037,5M_{9,t} - 2516,700M_{10,t} - 223,144M_{11,t} \\
 & + 7854,900M_{12,t} - 9217,1V_{1,t} + 4529,500V_{2,t} + 4883,000V_{3,t} \\
 & + 5274,100V_{4,t} + 18234,000V_{1,t+1} + 6643,2V_{2,t+1} + 3023,400V_{3,t+1} \\
 & + 2891,800V_{4,t+1} + \frac{1 - 0,855B + 0,482B^{12} - 0,299B^{13}}{(1 + 0,176B^{23})(1 - B)} a_t
 \end{aligned}$$

j. Model ARIMAX pecahan *outflow* Rp 20.000,00

$$\begin{aligned}
 Y_{10,t} = & 0,238T_t^* - 341,586M_{1,t} - 296,993M_{2,t} + 54,267M_{3,t} \\
 & + 79,334M_{4,t} + 31,209M_{5,t} + 228,090M_{6,t} + 44,379M_{7,t} \\
 & - 287,329M_{8,t} - 348,289M_{9,t} - 131,891M_{10,t} - 234,086M_{11,t} \\
 & + 249,140M_{12,t} - 1459,300V_{1,t} - 595,110V_{2,t} + 195,394V_{3,t} \\
 & + 639,237V_{4,t} + 1680,5V_{1,t+1} + 1111,300V_{2,t+1} + 737,690V_{3,t+1} \\
 & + 370,918V_{4,t+1} + \frac{1 + 0,808B^{13}}{(1 + 0,345B - 0,273B^{12})(1 - B)} a_t
 \end{aligned}$$

k. Model ARIMAX pecahan *outflow* Rp 10.000,00

$$\begin{aligned}
 Y_{11,t} = & 0,273T_t^* + 489,907M_{1,t} + 381,886M_{2,t} + 407,311M_{3,t} \\
 & + 464,054M_{4,t} + 475,10715M_{5,t} + 573,680M_{6,t} \\
 & + 712,752M_{7,t} + 655,320M_{8,t} + 188,410M_{9,t} \\
 & + 204,448M_{10,t} + 237,647M_{11,t} + 447,785M_{12,t} \\
 & - 217,031V_{1,t} + 200,574V_{2,t} + 603,043V_{3,t} + 1185,6V_{4,t} \\
 & + 1186,500V_{1,t+1} + 1412,800V_{2,t+1} + 537,053V_{3,t+1} \\
 & + 402,583V_{4,t+1} + a_t + 0,461a_{t-12} + 0,542a_{t-23}
 \end{aligned}$$

l. Model ARIMAX pecahan *outflow* Rp 5.000,00

$$\begin{aligned}
 Y_{12,t} = & 0,843T_t^* + 219,775M_{1,t} + 189,555M_{2,t} \\
 & + 215,926M_{3,t} + 255,424M_{4,t} + 283,504M_{5,t} \\
 & + 386,832M_{6,t} + 462,804M_{7,t} + 349,138M_{8,t} \\
 & + 69,746M_{9,t} + 36,569M_{10,t} + 49,652M_{11,t} \\
 & + 221,016M_{12,t} - 132,159V_{1,t} + 421,755V_{2,t} \\
 & + 613,182V_{3,t} + 1055,000V_{4,t} + 1282,400V_{1,t+1} \\
 & + 1743,500V_{2,t+1} + 538,580V_{3,t+1} + 482,933V_{4,t+1} \\
 & + a_t + 0,353a_{t-11} - 0,647a_{t-24}
 \end{aligned}$$


m. Model ARIMAX pecahan *outflow* Rp 2.000,00

$$\begin{aligned}
 Y_{13,t} = & 2,160T_t^* + 64,563M_{1,t} + 58,323M_{2,t} + 66,052M_{3,t} \\
 & + 83,127M_{4,t} + 119,554M_{5,t} + 136,345M_{6,t} + 146,193M_{7,t} \\
 & - 286,555M_{8,t} - 39,989M_{9,t} + 15,747M_{10,t} + 27,631M_{11,t} \\
 & + 87,224M_{12,t} + 283,778V_{2,t} + 980,177V_{3,t} + 1631,600V_{4,t} \\
 & + 1478,000V_{2,t+1} + 658,069V_{3,t+1} + 153,528V_{4,t+1}
 \end{aligned}$$


n. Model ARIMAX pecahan *outflow* Rp 1.000,00

$$\begin{aligned}
 Y_{14,t} = & -0,043T_t^* - 33,028M_{1,t} - 47,041M_{2,t} - 28,274M_{3,t} \\
 & - 25,683M_{4,t} - 23,126M_{5,t} - 12,790M_{6,t} - 12,062M_{7,t} \\
 & + 6,329M_{8,t} + 1,638M_{9,t} + 3,292M_{10,t} - 79,181M_{11,t} \\
 & - 15,812M_{12,t} - 63,120V_{1,t} + 208,729V_{2,t} + 255,550V_{3,t} \\
 & + 290,856V_{4,t} + 269,312V_{1,t+1} + 86,704V_{2,t+1} + 33,563V_{3,t+1} \\
 & - 1,635V_{4,t+1} + \frac{1 - 0,567B - 0,275B^{23}}{(1 - 0,407B^{12} - 0,590B^{23})(1 - B)} a_t
 \end{aligned}$$


Setelah didapatkan model ARIMAX untuk masing-masing pecahan, berikut disajikan perbandingan hasil ramalan berdasarkan data *in-sample* dan *out-sample*.




Gambar 4.29 Time Series Plot Perbandingan Hasil Ramalan ARIMAX per Pecahan *Inflow* dan *Outflow*




Gambar 4.29 Time Series Plot Perbandingan Hasil Ramalan ARIMAX per Pecahan *Inflow* dan *Outflow* (Lanjutan)



Gambar 4.29 Time Series Plot Perbandingan Hasil Ramalan ARIMAX per Pecahan *Inflow* dan *Outflow* (Lanjutan)



Gambar 4.29 Time Series Plot Perbandingan Hasil Ramalan ARIMAX per Pecahan *Inflow* dan *Outflow* (Lanjutan)



Gambar 4.29 Time Series Plot Perbandingan Hasil Ramalan ARIMAX per Pecahan Inflow dan Outflow (Lanjutan)

Berdasarkan Gambar 4.29 dapat dilihat secara umum model ARIMAX mampu menangkap efek variasi kalender hari raya Idul Fitri. Hasil ramalan yang ditunjukkan dapat mengikuti pola data aktual *in-sample* dengan baik, namun untuk data *out-sample* hasil ramalan model ARIMAX terlihat memiliki selisih yang cukup besar dengan data aktual. Kesalahan peramalan pada pecahan *inflow* dan *outflow* Rp 1.000,00 dapat disebabkan karena hasil ramalan menunjukkan adanya variasi kalender sedangkan pada kenyataannya data *out-sample* pecahan Rp 1.000,00 semakin lama semakin tidak terlihat efek variasinya. Pada pecahan *outflow* Rp 20.000,00 dan Rp 1.000,00 hasil peramalan interval dapat memuat keseluruhan data *out-sample*. Peramalan interval untuk pecahan lainnya tidak memuat keseluruhan data *out-sample* tetapi sudah memuat sebagian besar data *out-sample*.

Selanjutnya disajikan perhitungan manual peramalan 1 tahap ke depan ($t = 133$) yaitu bulan Januari 2014 untuk *inflow* Rp 100.000,00 berdasarkan model ARIMAX. Model ARIMAX *inflow* Rp 100.000,00 ditunjukkan oleh persamaan:

$$\begin{aligned}
 Y_t = & 3,0187I_t^* + 6838,300M_{1,t} - 6254,700M_{2,t} - 584,421M_{3,t} \\
 & - 68,888M_{4,t} + 5,536M_{5,t} - 113,847M_{6,t} + 2156,300M_{7,t} \\
 & - 531,924M_{8,t} - 1959,500M_{9,t} - 1836,000M_{10,t} - 2630,000M_{11,t} \\
 & - 2428,900M_{12,t} + 13014,400V_{1,t} + 14323,600V_{2,t} + 7247,200V_{3,t} \\
 & + 3001,700V_{4,t} - 5915,800V_{1,t+1} - 9444,100V_{2,t+1} - 2061,100V_{3,t+1} \\
 & + 4453,4V_{4,t+1} + \frac{1 - 0,792B - 0,208B^{13}}{(1 - 0,584B^{23})(1 - B)} a_t.
 \end{aligned}$$

Kedua sisi persamaan dikalikan dengan $\{(1 - 0,584B^{23})(1 - B)\}$ sehingga tidak ada lagi penyebut dalam persamaan. Perkalian $\{(1 - 0,584B^{23})(1 - B)\}$ dengan sisi kiri persamaan dapat ditunjukkan dalam perhitungan berikut.

$$\begin{aligned}(1 - 0,584B^{23})(1 - B)Y_t &= (1 - B - 0,584B^{23} + 0,584B^{24})Y_t \\ &= Y_t - Y_{t-1} - 0,584Y_{t-23} + 0,584Y_{t-24}.\end{aligned}$$

Jika sisi kiri persamaan didefinisikan sebagai C maka substitusi $t=133$ terhadap C yaitu:

$$\begin{aligned}C &= Y_{133} - Y_{133-1} - 0,584Y_{133-23} + 0,584Y_{133-24} \\ &= Y_{133} - Y_{132} - 0,584Y_{110} + 0,584Y_{109}.\end{aligned}$$

Misal R adalah sisi kanan persamaan, maka perkalian sisi kanan persamaan dengan $\{(1 - 0,58444B^{23})(1 - B)\}$ dapat ditunjukkan seperti perhitungan berikut.

$$\begin{aligned}R &= \{3,0179T_t^* + 6838,300M_{1,t} - 6254,700M_{2,t} - 584,421M_{3,t} \\ &\quad - 68,888M_{4,t} + 5,536M_{5,t} - 113,847M_{6,t} + 2156,300M_{7,t} \\ &\quad - 531,924M_{8,t} - 1959,500M_{9,t} - 1836,000M_{10,t} - 2630,000M_{11,t} \\ &\quad - 2428,900M_{12,t} + 13014,400V_{1,t} + 14323,600V_{2,t} + 7247,200V_{3,t} \\ &\quad + 3001,700V_{4,t} - 5915,800V_{1,t+1} - 9444,100V_{2,t+1} - 2061,100V_{3,t+1} \\ &\quad + 4453,400V_{4,t+1}\}(1 - 0,584B^{23})(1 - B) \\ &\quad + (1 - 0,792B - 0,208B^{13})a_t \\ &= \{3,0179T_t^* + 6838,300M_{1,t} - 6254,700M_{2,t} - 584,421M_{3,t} \\ &\quad - 68,888M_{4,t} + 5,536M_{5,t} - 113,847M_{6,t} + 2156,300M_{7,t} \\ &\quad - 531,924M_{8,t} - 1959,500M_{9,t} - 1836,000M_{10,t} - 2630,000M_{11,t} \\ &\quad - 2428,900M_{12,t} + 13014,400V_{1,t} + 14323,600V_{2,t} + 7247,200V_{3,t} \\ &\quad + 3001,700V_{4,t} - 5915,800V_{1,t+1} - 9444,100V_{2,t+1} - 2061,100V_{3,t+1} \\ &\quad + 4453,400V_{4,t+1}\}(1 - B - 0,58444B^{23} + 0,58444B^{24}) \\ &\quad + a_t - 0,7921a_{t-1} - 0,2079a_{t-13}\end{aligned}$$

Kemudian disubstitusikan nilai $t=133$ sehingga R menjadi:

$$\begin{aligned}
 R = & \{3,0179T_{133}^* + 6838,300M_{1,133} - 6254,700M_{2,133} - 584,421M_{3,133} \\
 & - 68,888M_{4,133} + 5,536M_{5,133} - 113,847M_{6,133} + 2156,300M_{7,133} \\
 & - 531,924M_{8,133} - 1959,500M_{9,133} - 1836,000M_{10,133} - 2630,000M_{11,133} \\
 & - 2428,900M_{12,133} + 13014,400V_{1,133} + 14323,600V_{2,133} + 7247,200V_{3,133} \\
 & + 3001,700V_{4,133} - 5915,800V_{1,134} - 9444,100V_{2,134} - 2061,100V_{3,134} \\
 & + 4453,400V_{4,134} \} (1 - 0,584B^{23})(1 - B) \\
 & + a_{133} - 0,792a_{132} - 0,208a_{120}.
 \end{aligned}$$

Diketahui nilai-nilai yang variabel *dummy* untuk bulan Januari 2014 yaitu:

$$\begin{array}{llll}
 T_{133}^* = 133, & M_{5,133} = 0, & M_{10,133} = 0, & V_{3,133} = 0, \\
 M_{1,133} = 1, & M_{6,133} = 0, & M_{11,133} = 0, & V_{4,133} = 0, \\
 M_{2,133} = 0, & M_{7,133} = 0, & M_{12,133} = 0, & V_{1,134} = 0, \\
 M_{3,133} = 0, & M_{8,133} = 0, & V_{1,133} = 0, & V_{2,134} = 0, \\
 M_{4,133} = 0, & M_{9,133} = 0, & V_{2,133} = 0, & V_{3,134} = 0, \\
 & & & V_{4,134} = 0.
 \end{array}$$

Dengan mensubstitusikan variabel-variabel *dummy* di atas maka R menjadi:

$$\begin{aligned}
 R = & (3,018T_{133}^* + 6838,300M_{1,133})(1 - B - 0,584B^{23} + 0,584B^{24}) \\
 & + a_{133} - 0,792a_{132} - 0,208a_{120} \\
 = & 3,018T_{133} - 3,018T_{133-1} - 3,08(0,584)T_{133-23} \\
 & + 3,018(0,584)T_{133-24} + 6838,300M_{1,133} - 6838,300M_{1,133-1} \\
 & - 6838,300(0,584)M_{1,133-23} + 6838,300(0,584)M_{1,133-24} \\
 & + a_{133} - 0,792a_{132} - 0,208a_{120}
 \end{aligned}$$

Selanjutnya sisi kiri (C) disamakan dengan sisi kanan (R).

$$C = R$$

$$\begin{aligned}
& Y_{133} - Y_{132} - 0,584Y_{110} + 0,584Y_{109} \\
& \Leftrightarrow 3,018T_{133}^* - 3,018T_{133-1}^* - 3,018(0,584)T_{133-23}^* \\
& \quad + 3,018(0,584)T_{133-24}^* + 6838,300M_{1,133} - 6838,300M_{1,133-1} \\
& \quad - 6838,300(0,584)M_{1,133-23} + 6838,300(0,584)M_{1,133-24} \\
& \quad + a_{133} - 0,792a_{132} - 0,208a_{120} \\
& Y_{133} = Y_{132} + 0,584Y_{110} - 0,584Y_{109} \\
& \quad + 3,018T_{133}^* - 3,018T_{132}^* - 3,018(0,584)T_{110}^* \\
& \quad + 3,018(0,584)T_{109}^* + 6838,300M_{1,133} - 6838,300M_{1,132} \\
& \quad - 6838,300(0,584)M_{1,110} + 6838,300(0,584)M_{1,109} \\
& \quad + a_{133} - 0,792a_{132} - 0,208a_{120}
\end{aligned}$$

Berikut disajikan nilai-nilai yang dibutuhkan untuk menghitung persamaan di atas.

$Y_{132} = 9995,215$	$a_{133} = 0,000$	$T_{133}^* = 133$	$M_{1,133} = 1$
$Y_{110} = 1405,648$	$a_{132} = -7738,925$	$T_{132}^* = 132$	$M_{1,132} = 0$
$Y_{109} = 21279,111$	$a_{120} = 2709,377$	$T_{110}^* = 110$	$M_{1,110} = 0$
		$T_{109}^* = 109$	$M_{1,109} = 1$

Dengan mensubstitusikan nilai-nilai di atas didapatkan hasil ramalan *inflow* bulan Januari 2014.

$$\begin{aligned}
Y_{133} &= 9995,215 + 0,584(14505,648) - 0,584(21279,111) \\
&\quad + 3,018(133) - 3,018(132) - 3,018(0,584)(11) \\
&\quad + 3,018(0,584)(109) + 6838,300(1) - 6838,300(0) \\
&\quad - 6838,300(0,584)(0) + 6838,300(0,584)(1) \\
&\quad + 0 - 0,792(-7738,925) - 0,208(-2709,377) \\
&= 23565,944
\end{aligned}$$

Berdasarkan perhitungan manual yang dilakukan didapatkan hasil ramalan untuk *inflow* bulan Januari 2014 sebesar Rp 23565,944 miliar rupiah. Hasil ramalan ARIMAX *inflow* Rp 100.000,00 dapat dengan *software* SAS dapat dilihat pada Lampiran 8.

Output SAS menunjukkan hasil ramalan untuk $t=133$ yaitu 23396,360 miliar. Perbedaan hasil ramalan manual dengan *output* SAS dapat disebabkan karena pembulatan yang dilakukan.

Selanjutnya dilakukan evaluasi model ARIMAX untuk keseluruhan pecahan *inflow* dan *outflow* berdasarkan kriteria RMSE, MAPE, sMAPE dan sMdAPE seperti pada Tabel 4.25.

Tabel 4.25 Nilai Kebaikan Model ARIMAX per Pecahan *Inflow* dan *Outflow*

Data	Pecahan	RMSE	MAPE	sMAPE	sMdAPE
<i>Inflow</i>	Rp 100.000,00	11222,41	34,94	30,25	24,20
	Rp 50.000,00	4666,69	21,57	16,35	14,93
	Rp 20.000,00	414,76	28,91	37,81	22,77
	Rp 10.000,00	308,12	24,58	29,77	26,66
	Rp 5.000,00	186,01	14,43	15,79	9,23
	Rp 2.000,00	131,30	53,49	34,14	34,87
	Rp 1.000,00	25,98	132,99	810,67	179,75
<i>Outflow</i>	Rp 100.000,00	9880,05	34,75	28,27	26,18
	Rp 50.000,00	5893,42	32,80	24,91	22,69
	Rp 20.000,00	967,92	273,89	78,13	63,68
	Rp 10.000,00	731,34	72,00	31,56	23,48
	Rp 5.000,00	5893,42	32,80	24,91	22,69
	Rp 2.000,00	293,10	86,30	72,87	38,06
	Rp 1.000,00	116,27	2697,26	349,06	226,04

Tabel 4.25 menunjukkan nilai evaluasi model ARIMAX untuk masing-masing pecahan *inflow* dan *outflow* berdasarkan data *out-sample*. Dapat dilihat bahwa bahwa hasil ramalan memiliki kesalahan yang cukup besar karena nilai RMSE, MAPE, sMAPE dan sMdAPE yang dihasilkan cukup besar.

4.4 Pemodelan Data *Inflow* dan *Outflow* dengan SSA-ANFIS


Pemodelan SSA-ANFIS juga dilakukan terhadap masing-masing pecahan uang kartal. Pembagian data *in-sample* dan *out-sample* pada pemodelan SSA-ANFIS tidak dilakukan di awal seperti metode ARIMAX, namun dilakukan setelah melewati

tahap dekomposisi SSA dan sebelum memasuki tahap peramalan ANFIS. Hal ini dikarenakan pada tahap pemodelan ANFIS dibutuhkan data *out-sample* untuk menentukan model ANFIS mana yang terbaik dari kombinasi jenis fungsi keanggotaan dan *input* model yang berbeda. Data *out-sample* yang digunakan sama seperti sebelumnya yaitu 3 tahun atau 36 data terakhir.

Deret X pada data *inflow* pecahan Rp 100.000,00 yaitu $X = \{7666,245, 5308,464, \dots, 20162,623\}$. Dengan menggunakan nilai $L=85$, berikut matriks lintasan \mathbf{X} yang terbentuk.


$$\mathbf{X} = (x_{ij})_{i,j=1}^{85,84} = \begin{bmatrix} 7666,245 & 5308,464 & \cdots & 3688,827 \\ 5308,464 & 5134,964 & \cdots & 12023,700 \\ \vdots & \vdots & \ddots & \vdots \\ 12023,700 & 4614,230 & \cdots & 20162,623 \end{bmatrix}$$

Matriks lintasan \mathbf{X} di atas didekomposisi menjadi 50 *eigentriple* yang terdiri dari dimana plot nilai singularnya dapat dilihat pada Gambar 4.30.



Gambar 4.30 Plot Nilai Singular Data *Inflow* Pecahan Rp 100.000,00

Dengan melihat Gambar 4.30 didapatkan bahwa *eigentriple* 13 sampai dengan *eigentriple* 50 menurun secara lambat sehingga *eigentriple* tersebut dikelompokkan ke dalam kelompok *noise*. Karena pengelompokan *noise* tersebut maka *eigentriple* utama yang terbentuk yaitu 12 *eigentriple*. *Eigentriple* utama ini selanjutnya akan dikelompokkan ke dalam kelompok *trend* dan *seasonality* sesuai dengan plot *eigentriple* tersebut. Plot dari 12 *eigentriple* utama ditampilkan dalam Gambar 4.31.



Gambar 4.31 Plot *Eigentriple* Utama pada Data *Inflow* Pecahan Rp 100.000,00


Pengelompokan *seasonality* berdasarkan *eigentriple* utama dapat ditentukan dengan melihat pola variasi pada Gambar 4.31 dan periode musiman pada Tabel 4.26.

Tabel 4.26 Pengelompokan *Eigentriple* Data *Inflow* Pecahan Rp 100.000,00

<i>Eigentriple</i>	Periode (Bulan)	<i>Eigentriple</i>	Periode (Bulan)
1	-	7	-
2	6	8	2
3	6	9	2
4	3	10	4
5	3	11	4
6	-	12	-

Hasil pengelompokan *seasonality* sesuai dengan Tabel 4.26 yaitu *eigentriple* 2, *eigentriple* 3, *eigentriple* 4, *eigentriple* 5, *eigentriple* 8, *eigentriple* 9, *eigentriple* 10, dan *eigentriple* 11. Pengelompokan ke dalam kelompok *seasonality* didasarkan pola variasi yang cepat serta periode musiman bulanan yang sama. *Eigentriple* 1 dikelompokkan ke dalam kelompok *trend* karena

pola variasi yang ditunjukkan lambat serta tidak memiliki periode musiman. *Eigentriple* 6 tidak menunjukkan pola variasi lambat dan tidak memiliki periode musiman sehingga *eigentriple* 6 ini dikelompokkan ke dalam kelompok *noise*. *Eigentriple* 7 dan 12 memiliki pola variasi lambat namun pergerakan polanya di sekitar 0 sehingga kedua *eigentriple* ini juga dikelompokkan ke dalam kelompok *noise*. Hasil rekonstruksi kelompok *trend*, *seasonality* dan *noise* dapat dilihat pada Gambar 4.32.



Gambar 4.32 Plot Hasil Rekonstruksi (a) *Trend* (b) *Seasonality* (c) *Noise*
Pecahan *Inflow* Rp 100.000,00

Berdasarkan hasil rekonstruksi masing-masing kelompok seperti pada Gambar 4.32 di atas dapat dilihat bahwa kelompok *seasonality* merupakan kelompok musiman ditambah dengan variasi kalender. *Syntax* dekomposisi SSA untuk pecahan *inflow*

Rp 100.000,00 disajikan dalam Lampiran 9. Dekomposisi SSA juga dilakukan terhadap pecahan yang lain. Tahap dekomposisi SSA secara lengkap untuk pecahan *inflow* dan *outflow* yang lain disajikan dalam Lampiran 10. Selanjutnya dilakukan tahap peramalan ANFIS pada hasil dekomposisi SSA. Peramalan ANFIS yang digunakan yaitu peramalan agregat. Dilakukan peramalan agregat karena hasil kajian simulasi menyatakan bahwa peramalan SSA-ANFIS secara agregat memberikan hasil yang lebih baik daripada peramalan individu.

Langkah awal yang dilakukan pada metode ANFIS adalah menentukan variabel *input* setiap kelompok. Penentuan variabel *input* dengan cara melihat plot PACF dari data stasioner dimana *lag* yang signifikan dapat dijadikan sebagai variabel *input*. Pengujian stasioneritas data untuk tiap kelompok hasil dekomposisi SSA pada pecahan *inflow* Rp 100.000,00 dapat disajikan dalam Tabel 4.27.

Tabel 4.27 Uji Dickey-Fuller pada Data Pecahan *Inflow* Rp 100.000,00

Kelompok	Dickey-Fuller	<i>P-value</i>
<i>Trend</i>	-0,308	0,99
<i>Seasonality</i>	-10,755	< 0,01
<i>Noise</i>	-4,332	< 0,01

Berdasarkan hasil uji Dickey-Fuller seperti pada Tabel 4.27 dapat dilihat bahwa *p-value* untuk kelompok *seasonality* dan *noise* lebih kecil dari taraf signifikansi (α) yaitu 0,05 sehingga dihasilkan keputusan tolak H_0 yang artinya data sudah stasioner. Dapat dilihat bahwa kelompok *trend* belum stasioner sehingga perlu dilakukan *differencing* agar data menjadi stasioner. Hasil uji stasioneritas data *trend* setelah *differencing lag-1* sebanyak 3 kali dapat ditunjukkan pada Tabel 4.28.

Tabel 4.28 Uji Dickey-Fuller pada Data *Trend* Hasil *Differencing* untuk Pecahan *Inflow* Rp 100.000,00

Kelompok	Dickey-Fuller	<i>P-value</i>
<i>Trend</i>	-10,315	< 0,01

Pengujian pada Tabel 4.28 menghasilkan kesimpulan bahwa data *trend* pada pecahan *inflow* Rp 100.000,00 sudah stasioner karena *p-value* uji Dickey-Fuller kurang dari taraf signifikansi 0,05 sehingga dapat dibuat plot PACFnya untuk menentukan variabel input ANFIS.

Hasil uji stasioneritas data melalui uji Dickey-Fuller disajikan dalam Tabel 4.29. Tabel tersebut menginformasikan bahwa kelompok *seasonality* tiap pecahan *inflow* dan *outflow* sudah stasioner, sedangkan kelompok *trend* hanya ada 1 pecahan yang stasioner yaitu *outflow* Rp 2.000,00. *Trend* yang belum *stasioner* *didifferencing* sampai didapatkan hasil bahwa *trend* tersebut sudah stasioner. Untuk kelompok *noise* yang belum stasioner yaitu pada pecahan *inflow* Rp 50.000,00 dan Rp 20.0000,00 serta *outflow* Rp 1.000,00.

Tabel 4.29 Uji Dickey-Fuller pada Data Pecahan *Inflow* dan *Outflow*

Data	Kelompok	Dickey-Fuller	<i>P-value</i>	Keputusan
<i>Inflow</i>				
Rp 50.000,00	<i>Trend</i>	-3,538	0,99	Tidak Stasioner
	<i>Seasonality</i>	-14,584	< 0,01	Stasioner
	<i>Noise</i>	-2,767	0,26	Tidak Stasioner
Rp 20.000,00	<i>Trend</i>	-1,860	0,64	Tidak Stasioner
	<i>Seasonality</i>	-11,058	< 0,01	Stasioner
	<i>Noise</i>	-2,581	0,33	Tidak Stasioner
Rp 10.000,00	<i>Trend</i>	1,480	> 0,99	Tidak Stasioner
	<i>Seasonality</i>	-17,606	< 0,01	Stasioner
	<i>Noise</i>	-4,327	< 0,01	Stasioner
Rp 5.000,00	<i>Trend</i>	3,370	> 0,99	Tidak Stasioner
	<i>Seasonality</i>	-21,566	< 0,01	Stasioner
	<i>Noise</i>	-5,754	< 0,01	Stasioner
Rp 2.000,00	<i>Trend</i>	-3,424	0,06	Tidak Stasioner
	<i>Seasonality</i>	-10,640	< 0,01	Stasioner
	<i>Noise</i>	-4,787	< 0,01	Stasioner
Rp 1.000,00	<i>Trend</i>	-0,507	0,98	Tidak Stasioner
	<i>Seasonality</i>	-17,297	< 0,01	Stasioner
	<i>Noise</i>	-3,636	0,03	Stasioner

Tabel 4.29 Uji Dickey-Fuller pada Data Pecahan *Inflow* dan *Outflow* (Lanjutan)


Data	Kelompok	Dickey-Fuller	<i>P-value</i>	Keputusan
<i>Outflow</i>				
Rp 100.000,00	<i>Trend</i>	4,959	> 0,99	Tidak Stasioner
	<i>Seasonality</i>	-12,765	< 0,01	Stasioner
	<i>Noise</i>	-4,648	< 0,01	Stasioner
Rp 50.000,00	<i>Trend</i>	-2,278	0,46	Tidak Stasioner
	<i>Seasonality</i>	-8,067	< 0,01	Stasioner
	<i>Noise</i>	-4,827	< 0,01	Stasioner
Rp 20.000,00	<i>Trend</i>	-8,982	0,43	Tidak Stasioner
	<i>Seasonality</i>	-4,902	< 0,01	Stasioner
	<i>Noise</i>	-3,733	< 0,01	Stasioner
Rp 10.000,00	<i>Trend</i>	2,862	> 0,99	Tidak Stasioner
	<i>Seasonality</i>	-9,443	< 0,01	Stasioner
	<i>Noise</i>	-6,142	< 0,01	Stasioner
Rp 5.000,00	<i>Trend</i>	0,707	> 0,99	Tidak Stasioner
	<i>Seasonality</i>	-12,843	< 0,01	Stasioner
	<i>Noise</i>	-8,461	< 0,01	Stasioner
Rp 2.000,00	<i>Trend</i>	-4,299	< 0,01	Stasioner
	<i>Seasonality</i>	-17,06	< 0,01	Stasioner
	<i>Noise</i>	-6,293	< 0,01	Stasioner
Rp 1.000,00	<i>Trend</i>	-0,127	> 0,99	Tidak Stasioner
	<i>Seasonality</i>	-8,708	< 0,01	Stasioner
	<i>Noise</i>	-3,408	0,06	Tidak Stasioner

Setelah dilakukan *differencing* pada data yang tidak stasioner, dilakukan uji stasioneritas kembali untuk mengetahui apakah data sudah stasioner atau belum. Tabel 4.30 menyajikan hasil pengujian stasioneritas pada hasil *differencing* kelompok *trend* dan *noise* hasil dekomposisi SSA pada masing-masing pecahan *inflow* dan *outflow* uang kartal di Indonesia dari pecahan Rp 50.000,00, Rp 20.000,00, Rp 10.000,00, Rp 5.000,00 dan Rp 1.000,00.

Tabel 4.30 Uji Dickey-Fuller pada Data Hasil *Differencing* Tiap Pecahan *Inflow* dan *Outflow*

Data	Dickey-Fuller	<i>P-value</i>	Keputusan
<i>Inflow</i>			
<i>Trend</i> Rp 50.000,00	-4,915	< 0,01	Stasioner
<i>Noise</i> Rp 50.000,00	-6,574	< 0,01	Stasioner
<i>Trend</i> Rp 20.000,00	-4,857	< 0,01	Stasioner
<i>Noise</i> Rp 20.000,00	-7,181	< 0,01	Stasioner
<i>Trend</i> Rp 10.000,00	-4,300	< 0,01	Stasioner
<i>Trend</i> Rp 5.000,00	-4,116	< 0,01	Stasioner
<i>Trend</i> Rp 2.000,00	-4,788	< 0,01	Stasioner
<i>Trend</i> Rp 1.000,00	-5,200	< 0,01	Stasioner
<i>Outflow</i>			
<i>Trend</i> Rp 100.000,00	-8,572	< 0,01	Stasioner
<i>Trend</i> Rp 50.000,00	-3,701	0,03	Stasioner
<i>Trend</i> Rp 20.000,00	-3,733	0,02	Stasioner
<i>Trend</i> Rp 10.000,00	-5,388	< 0,01	Stasioner
<i>Trend</i> Rp 5.000,00	-7,461	< 0,01	Stasioner
<i>Trend</i> Rp 1.000,00	-4,140	< 0,01	Stasioner
<i>Noise</i> Rp 1.000,00	-7,053	< 0,01	Stasioner

Berdasarkan Tabel 4.30 dapat dilihat bahwa dengan melakukan *differencing*, keseluruhan *p-value* uji Dickey-Fuller *trend* dan *noise* kurang dari taraf signifikansi 0,05 yang artinya sudah stasioner. Kemudian dibentuk plot PACF dari data-data yang sudah stasioner pada pecahan *inflow* Rp 100.000,00 seperti pada Gambar 4.33.



Gambar 4.33 Plot PACF Pecahan *Inflow* Rp 100.000,00 (a) *Trend* (b) *Noise* (c) *Seasonality* (d) *Differencing Seasonality*

Gambar 4.34 menunjukkan *lag* PACF yang memiliki signifikansi tertinggi pada masing-masing kelompok. Jika *trend* periode ke- t didefinisikan sebagai T_t , *seasonality* periode ke- t didefinisikan sebagai S_t dan *noise* periode ke- t didefinisikan sebagai N_t maka kemungkinan variabel *input* untuk *trend* berurutan dari *lag* dengan signifikansi tertinggi yaitu yaitu *lag*-1 (T_{t-1}), *lag*-5 (T_{t-5}), dan *lag*-2 (T_{t-2}). Penentuan variabel *input* untuk *seasonality* juga didasarkan pada PACF *differencing* musiman 12. Dari plot (c) didapatkan *lag* dengan signifikansi tertinggi yaitu *lag*-12 sedangkan pada plot (d) *lag* dengan signifikansi tertinggi yaitu *lag*-1 sehingga kemungkinan variabel *input* untuk *seasonality* yaitu *lag*-1 (S_{t-1}), *lag*-12 (S_{t-12}), dan *lag*-13 (S_{t-13}). Penentuan variabel *input* untuk *noise* sama dengan *trend* yaitu dengan melihat 3 *lag* signifikan tertinggi sehingga kemungkinan *input* untuk *noise* pecahan *inflow* Rp 100.000,00 yaitu *lag*-2 (N_{t-2}), *lag*-3 (N_{t-3}) dan *lag*-10 (N_{t-10}). Dengan melihat Lampiran 11 yaitu plot PACF dari data yang sudah stasioner dapat ditentukan variabel *input* masing-masing kelompok untuk tiap pecahan *inflow* dan *outflow* pada Tabel 4.31.

Tabel 4.31 Variabel *Input* ANFIS Masing-Masing Kelompok pada Pecahan *Inflow* dan *Outflow*

Data	Pecahan	Kelompok	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Inflow</i>	Rp 50.000,00	<i>Trend</i>	T_{t-4}	T_{t-3}, T_{t-4}	$T_{t-4}, T_{t-3}, T_{t-2}$
		<i>Seasonality</i>	S_{t-9}	S_{t-9}, S_{t-13}	$S_{t-9}, S_{t-13}, S_{t-21}$
		<i>Noise</i>	N_{t-1}^*	N_{t-1}^*, N_{t-13}^*	$N_{t-1}^*, N_{t-3}^*, N_{t-13}^*$
	Rp 20.000,00	<i>Trend</i>	T_{t-1}	T_{t-1}, T_{t-10}	-
		<i>Seasonality</i>	S_{t-9}	S_{t-9}, S_{t-34}	$S_{t-9}, S_{t-14}, S_{t-23}$
		<i>Noise</i>	N_{t-1}^*	N_{t-1}^*, N_{t-2}^*	$N_{t-1}^*, N_{t-2}^*, N_{t-11}^*$
	Rp 10.000,00	<i>Trend</i>	T_{t-1}	T_{t-1}, T_{t-2}	-
		<i>Seasonality</i>	S_{t-2}	S_{t-2}, S_{t-22}	$S_{t-2}, S_{t-22}, S_{t-24}$
		<i>Noise</i>	N_{t-1}^*	N_{t-1}^*, N_{t-3}^*	$N_{t-1}^*, N_{t-3}^*, N_{t-11}^*$
	Rp 5.000,00	<i>Trend</i>	T_{t-1}	T_{t-1}, T_{t-2}	$T_{t-1}, T_{t-2}, T_{t-5}$
		<i>Seasonality</i>	S_{t-2}	S_{t-2}, S_{t-26}	$S_{t-2}, S_{t-24}, S_{t-26}$
		<i>Noise</i>	N_{t-1}^*	N_{t-1}^*, N_{t-3}^*	$N_{t-1}^*, N_{t-3}^*, N_{t-4}^*$
	Rp 2.000,00	<i>Trend</i>	T_{t-1}	T_{t-1}, T_{t-4}	$T_{t-1}, T_{t-2}, T_{t-4}$
		<i>Seasonality</i>	S_{t-2}	S_{t-2}, S_{t-26}	$S_{t-2}, S_{t-24}, S_{t-26}$
		<i>Noise</i>	N_{t-1}^*	N_{t-1}^*, N_{t-3}^*	$N_{t-1}^*, N_{t-2}^*, N_{t-3}^*$
	Rp 1.000,00	<i>Trend</i>	T_{t-1}	T_{t-1}, T_{t-10}	$T_{t-1}, T_{t-10}, T_{t-12}$
		<i>Seasonality</i>	S_{t-4}	S_{t-4}, S_{t-28}	$S_{t-4}, S_{t-24}, S_{t-28}$
		<i>Noise</i>	N_{t-1}^*	N_{t-1}^*, N_{t-2}^*	$N_{t-1}^*, N_{t-2}^*, N_{t-10}^*$
<i>Outflow</i>	Rp 100.000,00	<i>Trend</i>	T_{t-5}	T_{t-5}, T_{t-4}	$T_{t-5}, T_{t-4}, T_{t-11}$
		<i>Seasonality</i>	S_{t-2}	S_{t-2}, S_{t-26}	$S_{t-2}, S_{t-24}, S_{t-26}$
		<i>Noise</i>	N_{t-12}^*	N_{t-10}^*, N_{t-12}^*	$N_{t-3}^*, N_{t-10}^*, N_{t-12}^*$
	Rp 50.000,00	<i>Trend</i>	T_{t-1}	T_{t-1}, T_{t-13}	$T_{t-1}, T_{t-5}, T_{t-13}$
		<i>Seasonality</i>	S_{t-8}	S_{t-8}, S_{t-20}	$S_{t-8}, S_{t-12}, S_{t-20}$
		<i>Noise</i>	N_{t-12}^*	N_{t-6}^*, N_{t-12}^*	$N_{t-6}^*, N_{t-12}^*, N_{t-16}^*$
	Rp 20.000,00	<i>Trend</i>	T_{t-1}	T_{t-1}, T_{t-7}	$T_{t-1}, T_{t-2}, T_{t-7}$
		<i>Seasonality</i>	S_{t-2}	S_{t-2}, S_{t-26}	$S_{t-2}, S_{t-24}, S_{t-26}$
		<i>Noise</i>	N_{t-1}^*	N_{t-1}^*, N_{t-10}^*	$N_{t-1}^*, N_{t-10}^*, N_{t-12}^*$
	Rp 10.000,00	<i>Trend</i>	T_{t-1}	T_{t-1}, T_{t-2}	$T_{t-1}, T_{t-2}, T_{t-8}$
		<i>Seasonality</i>	S_{t-2}	S_{t-2}, S_{t-26}	$S_{t-2}, S_{t-24}, S_{t-26}$
		<i>Noise</i>	N_{t-1}^*	N_{t-1}^*, N_{t-2}^*	$N_{t-1}^*, N_{t-2}^*, N_{t-7}^*$
	Rp 5.000,00	<i>Trend</i>	T_{t-1}	T_{t-1}, T_{t-2}	$T_{t-1}, T_{t-2}, T_{t-11}$
		<i>Seasonality</i>	S_{t-5}	S_{t-5}, S_{t-17}	$S_{t-5}, S_{t-12}, S_{t-17}$
		<i>Noise</i>	N_{t-1}^*	N_{t-1}^*, N_{t-2}^*	$N_{t-1}^*, N_{t-2}^*, N_{t-7}^*$
	Rp 2.000,00	<i>Trend</i>	T_{t-1}	-	-
		<i>Seasonality</i>	S_{t-2}	S_{t-2}, S_{t-14}	$S_{t-2}, S_{t-12}, S_{t-14}$
		<i>Noise</i>	N_{t-2}^*	N_{t-1}^*, N_{t-2}^*	$N_{t-1}^*, N_{t-2}^*, N_{t-6}^*$
	Rp 1.000,00	<i>Trend</i>	T_{t-1}	T_{t-1}, T_{t-12}	$T_{t-1}, T_{t-11}, T_{t-12}$
		<i>Seasonality</i>	S_{t-11}	S_{t-11}, S_{t-23}	$S_{t-11}, S_{t-12}, S_{t-23}$
		<i>Noise</i>	N_{t-1}^*	N_{t-1}^*, N_{t-2}^*	$N_{t-1}^*, N_{t-2}^*, N_{t-3}^*$

Peramalan dengan metode ANFIS dilakukan pada masing-masing kombinasi jenis dan jumlah fungsi keanggotaan. Jenis fungsi keanggotaan yang digunakan yaitu fungsi *Trapezoidal*, *Gaussian*, *Phi* dan *Generalize Bell* serta jumlah fungsi keanggotaan 2. Banyaknya variabel *input* juga dapat menentukan hasil ramalan sehingga pada kajian terapan ini dilakukan pemilihan jumlah variabel *input* yaitu 1 *input*, 2 *input*, dan 3 *input* dari *lag* PACF dengan signifikansi tertinggi. Prosedur pembentukan *cluster* ANFIS menggunakan *grid partition*. Pemilihan model ANFIS terbaik didasarkan pada nilai RMSE *out-sample* yang paling kecil. Berikut disajikan tabel perbandingan RMSE *out-sample* pada pecahan *inflow* Rp 100.000,00 untuk menentukan model ANFIS terbaik pada masing-masing kelompok.


Tabel 4.32 Perbandingan Nilai RMSE *Out-Sample* Model ANFIS untuk *Trend*, *Seasonality*, dan *Noise* Pecahan *Inflow* Rp 100.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	8401,0	8023,5	8054,5
	<i>Gaussian</i>	1570,9	493,7	2,4e+07
	<i>Phi</i>	7872,9	7927,2	8459,7
	<i>Generalized Bell</i>	923,9	2159,0	9,7e+25
<i>Seasonality</i>	<i>Trapezoidal</i>	9853,7	18562,0	709290,0
	<i>Gaussian</i>	12738,0	525150,0	2,6e+06
	<i>Phi</i>	9800,0	26948,0	1,2e+06
	<i>Generalized Bell</i>	12566,0	2,0e+13	5,9e+23
<i>Noise</i>	<i>Trapezoidal</i>	6170,7	6808,3	7648,8
	<i>Gaussian</i>	6068,6	6382,0	6796,9
	<i>Phi</i>	6274,6	6999,6	7414,2
	<i>Generalized Bell</i>	6184,5	6760,3	6779,4

Nilai RMSE yang cukup besar mengindikasikan adanya kesalahan hasil ramalan yang cukup besar sehingga model terbaik merupakan model dengan nilai RMSE terkecil. Pada Tabel 4.32 nilai RMSE terkecil dicetak tebal. Berdasarkan tabel tersebut,


model ANFIS terbaik untuk kelompok *trend* pada data pecahan *inflow* Rp 100.000,00 yaitu ANFIS dengan fungsi keanggotaan *Phi* dan 3 variabel *input*. Model ANFIS terbaik untuk kelompok *seasonality* yaitu model ANFIS dengan fungsi keanggotaan *Phi* dan satu variabel *input* sedangkan kelompok *noise* dimodelkan dengan ANFIS fungsi keanggotaan *Gaussian* dan satu variabel *input*.

Berikutnya ditunjukkan plot hasil ramalan ANFIS pada tiap kelompok hasil dekomposisi SSA pecahan *inflow* Rp 100.000,00 berdasarkan data *in-sample* dan data *out-sample*.



Gambar 4.34 Plot Hasil Ramalan (a) *Trend* (b) *Seasonality* (c) *Noise* pada Pecahan *Inflow* Rp 100.000,00


Hasil ramalan metode ANFIS pada Gambar 4.34 ditunjukkan oleh plot warna merah dan data aktual ditunjukkan oleh plot warna biru. Dapat dilihat bahwa hasil ramalan untuk data *in-sample* mengikuti pola data aktualnya bahkan pada kelompok *trend* tidak terlihat adanya perbedaan data aktual dan ramalan. Hasil ramalan pada data *out-sample* juga sudah cukup baik untuk kelompok *trend* dan *seasonal* namun untuk kelompok *noise* terlihat kurang baik karena hasil ramalan tidak dapat mengikuti pola data *noise out-sample*. Selanjutnya hasil ramalan keseluruhan SSA-ANFIS untuk pecahan *inflow* Rp 100.000,00 didapatkan dengan menjumlahkan hasil ramalan kelompok *trend*, *seasonality* dan kelompok *noise*. Gambar 4.35 menunjukkan plot hasil ramalan metode SSA-ANFIS terhadap pecahan *inflow* Rp 100.000,00.



Gambar 4.35 Plot Hasil Ramalan SSA-ANFIS pada Pecahan *Inflow* Rp 100.000,00

Kelompok *seasonality* pada pecahan *inflow* Rp 100.000,00 memiliki pengaruh yang kuat terhadap hasil ramalan SSA-ANFIS karena *range* ramalan yang ditunjukkan sangat tinggi sehingga hasil ramalan *out-sample* SSA-ANFIS membentuk pola yang hampir sama dengan pola ramalan *seasonalnya*. Untuk data *in-sample* dapat diperhatikan bahwa hasil jumlahan ramalan ketiga kelompok tidak terlalu tepat. Hal ini dikarenakan ramalan *noise in-sample* tidak persis mengikuti pola datanya. *Syntax* ANFIS untuk masing-masing kelompok pecahan *inflow* Rp 100.000,00 disajikan dalam Lampiran 12.

Selanjutnya disajikan struktur ANFIS yang terbentuk untuk tiap kelompok pecahan *inflow* Rp 100.000,00.



Gambar 4.36 Struktur ANFIS Kelompok Pecahan *Inflow* Rp 100.000,00

Gambar 4.36(a) merupakan struktur ANFIS untuk kelompok *trend* pada pecahan *inflow* Rp 100.000,00 sedangkan Gambar 4.36(b) merupakan struktur ANFIS untuk kelompok *seasonality* dan *noise*. Struktur yang terbentuk pada ketiga kelompok berbeda-beda karena jumlah *input* model yang terpilih berbeda untuk kelompok *trend* dengan *seasonality* dan *noise*. Kelompok *trend* dengan 2 *input* sedangkan kelompok *noise* dan *seasonality* dengan 1 *input*. Pada struktur ANFIS *trend* dapat dilihat ada sebanyak 4 *rule* atau aturan yang terbentuk. Variabel *input trend* yang digunakan yaitu T_{t-1} dan T_{t-5} sehingga ke-4 aturan yang terbentuk dapat dijelaskan sebagai berikut:

1. Jika T_{t-1} adalah A_1 dan T_{t-5} adalah B_1 maka $T_{1t} = h_{1,1} T_{t-1} + h_{1,2} T_{t-5} + h_{1,3}$,
2. Jika T_{t-1} adalah A_1 dan T_{t-5} adalah B_2 maka $T_{2t} = h_{2,1} T_{t-1} + h_{2,2} T_{t-5} + h_{2,3}$,
3. Jika T_{t-1} adalah A_2 dan T_{t-5} adalah B_1 maka $T_{3t} = h_{3,1} T_{t-1} + h_{3,2} T_{t-5} + h_{3,3}$,
4. Jika T_{t-1} adalah A_2 dan T_{t-5} adalah B_2 maka $T_{4t} = h_{4,1} T_{t-1} + h_{4,2} T_{t-5} + h_{4,3}$.

Karena ada 4 aturan, maka data *trend* dikelompokkan menjadi 4 kelompok dengan metode *grid partition* untuk menentukan nilai awal dari parameter premis yaitu parameter fungsi keanggotaan A_r^* dan B_r^* . Nilai awal parameter premis untuk fungsi keanggotaan *Gaussian* pada data *trend inflow* pecahan Rp 100.000,00 diberikan dalam Tabel 4.33.

Tabel 4.33 Estimasi Awal Parameter Premis Fungsi *Phi* untuk ANFIS
Kelompok *Trend* Pecahan *Inflow* Rp 100.000,00

Fungsi Keanggotaan	Input T_{t-1}	Input T_{t-2}
1	$\sigma_{11} = 7034$ $c_{11} = 2984$	$\sigma_{12} = 6522$ $c_{12} = 2984$
2	$\sigma_{21} = 7034$ $c_{21} = 19550$	$\sigma_{22} = 6522$ $c_{22} = 18340$

Dalam bentuk persamaan fungsi *Gaussian*, parameter premis diatas dapat dituliskan sebagai:

$$\mu_{A1}(T_{t-1}) = e^{\frac{-(T_{t-1}-2984)^2}{2(7034)^2}}, \mu_{A2}(T_{t-1}) = e^{\frac{-(T_{t-1}-19550)^2}{2(7034)^2}},$$

$$\mu_{B1}(T_{t-5}) = e^{\frac{-(T_{t-5}-2984)^2}{2(6522)^2}}, \mu_{B2}(T_{t-5}) = e^{\frac{-(T_{t-5}-18340)^2}{2(6522)^2}}.$$

Struktur ANFIS terdiri dari 5 *layer*. Pada *layer* 1, variabel *input* T_{t-1} di ubah menjadi derajat keanggotaan μ_{A1} dan μ_{A2} , variabel *input* T_{t-5} di ubah menjadi derajat keanggotaan μ_{B1} dan μ_{B2} . *Output* pada *layer* 1 yang berupa 4 derajat keanggotaan dijadikan *input* untuk *layer* 2.

Output layer 2 didapatkan dengan menerapkan operator AND. *Output layer* 2 merupakan hasil perkalian antara derajat keanggotaan pada setiap aturan yaitu:

$$w_{1,t}^{(1)} = \mu_{A1}(T_{t-1}) \times \mu_{B1}(T_{t-5}),$$

$$w_{2,t}^{(1)} = \mu_{A1}(T_{t-1}) \times \mu_{B2}(T_{t-5}),$$

$$w_{3,t}^{(1)} = \mu_{A2}(T_{t-1}) \times \mu_{B1}(T_{t-5}),$$

$$w_{4,t}^{(1)} = \mu_{A2}(T_{t-1}) \times \mu_{B2}(T_{t-5}).$$

Selanjutnya 4 *output layer* 2 ini dijadikan *input layer* 3. Pada *layer* 3 dilakukan normalisasi *input* untuk mendapatkan nilai *normalized firing strength* ($\bar{w}_{g,t}^{(1)}$).

Kemudian dilakukan perhitungan parameter konsekuen atau parameter linier pada *layer* 4 yaitu $\{h_{g,1}, h_{g,2}, h_{g,3}\}$ dengan

$g=1,2,3,4$. Algoritma *hybrid* mengestimasi parameter konsekuen dengan metode *least square* secara maju dan parameter premis diestimasi dengan metode *backpropagation error*. Estimasi akhir parameter konsekuen dapat disajikan dalam Tabel 4.34.

Tabel 4.34 Estimasi Akhir Parameter Konsekuen Fungsi *Phi* Untuk ANFIS Kelompok *Trend* Pecahan *Inflow* Rp 100.000,00

g	$h_{g,1}$	$h_{g,2}$	$h_{g,3}$
1	1,114	-0,100	1,518
2	-1,678	3,736	-55,900
3	6,916	-7,116	-51,930
4	0,930	0,084	107,200

Setelah mendapatkan parameter konsekuen, selanjutnya menghitung nilai *output layer 5*. *Output* dari *layer 5* merupakan model matematis yang digunakan untuk peramalan dalam metode ANFIS. Dengan menggunakan nilai *normalized firing strength* (\bar{w}_i) dan parameter konsekuen seperti Tabel 4.34 didapatkan persamaan matematis model ANFIS untuk kelompok *trend* pecahan *inflow* Rp 100.000,00 sebagai berikut.

$$\begin{aligned}
 \hat{T}_t &= \bar{w}_{1,t}^{(1)} T_{1t} + \bar{w}_{2,t}^{(1)} T_{2t} + \bar{w}_{3,t}^{(1)} T_{3t} + \bar{w}_{4,t}^{(1)} T_{4t} \\
 &= \bar{w}_{1,t}^{(1)} (1,114T_{t-1} - 0,1002T_{t-5} + 1,518) + \bar{w}_{2,t}^{(1)} (-1,678T_{t-1} + 3,736T_{t-5} - 55,9) + \\
 &\quad \bar{w}_{3,t}^{(1)} (6,916T_{t-1} - 7,116T_{t-5} - 51,93) + \bar{w}_{4,t}^{(1)} (0,9303T_{t-1} + 0,0837T_{t-5} + 107,2)
 \end{aligned}$$

Tabel 4.35 merupakan estimasi awal parameter premis untuk kelompok *seasonality* dan *noise*.

Tabel 4.35 Estimasi Awal Parameter Premis Kelompok *Seasonality* dan *Noise* Pecahan *Inflow* Rp 100.000,00

Fungsi Keanggotaan	<i>Input</i> S_{t-12}		<i>Input</i> N_{t-2}^*
1	$a_{11} = -17720$ $c_{11} = -1410$	$b_{11} = -11200$ $d_{11} = 5116$	$\sigma_{11} = 8355$ $c_{11} = -6454$
2	$a_{21} = -1409$ $c_{21} = 14900$	$b_{21} = 5116$ $d_{21} = 21430$	$\sigma_{21} = 8355$ $c_{21} = 13220$

Sesuai dengan Tabel 4.35, derajat keanggotaan *input seasonality* dapat ditulis dalam fungsi keanggotaan *Phi* sedangkan *input noise* dalam bentuk fungsi keanggotaan *Gaussian*.

Seasonality:

$$\mu_{A1}(S_{t-12}) = \begin{cases} 0; & S_{t-12} \leq -17720 \\ 2[(S_{t-12} + 17720)/(6520)]^2; & -17720 \leq S_{t-12} \leq -14460 \\ 1 - 2[(-11200 - S_{t-12})/6520]^2; & -14460 \leq S_{t-12} \leq -11200 \\ 1; & -11200 \leq S_{t-12} \leq -1410 \\ 1 - 2[(S_{t-12} + 1410)/6526]^2; & -1410 \leq S_{t-12} \leq 1853 \\ 2[(5116 - S_{t-12})/6526]^2; & 1853 \leq S_{t-12} \leq 5116 \\ 0; & S_{t-12} \geq 5116 \end{cases}$$

$$\mu_{A2}(S_{t-12}) = \begin{cases} 0; & S_{t-12} \leq -1409 \\ 2[(S_{t-12} + 1409)/6525]^2; & -1409 \leq S_{t-12} \leq 1853,5 \\ 1 - 2[(5116 - S_{t-12})/6525]^2; & 1853,5 \leq S_{t-12} \leq 5116 \\ 1; & 5116 \leq S_{t-12} \leq 14900 \\ 1 - 2[(S_{t-12} - 14900)/6530]^2; & 14900 \leq S_{t-12} \leq 18165 \\ 2[(21430 - S_{t-12})/6530]^2; & 18165 \leq S_{t-12} \leq 21430 \\ 0; & S_{t-12} \geq 21430 \end{cases}$$

Noise:

$$\mu_{A1}(N_{t-2}^*) = e^{\frac{-(N_{t-2}^* + 6454)^2}{2(8355)^2}}$$

$$\mu_{A2}(N_{t-2}^*) = e^{\frac{-(N_{t-2}^* - 13220)^2}{2(8355)^2}}$$

Jika derajat keanggotaan di atas dijadikan *input layer 2* maka didapatkan $w_1^{(2)} = f_{A1}(S_{t-12})$, $w_2^{(2)} = f_{A2}(S_{t-12})$, $w_1^{(3)} = \mu_{A1}(N_{t-2}^*)$, $w_2^{(3)} = \mu_{A2}(N_{t-2}^*)$. Pada *layer 3* didapatkan *normalized firing strength* masing-masing aturan sehingga persamaan matematis untuk *seasonality* dan *noise* yaitu:

Seasonality:

$$\begin{aligned} \hat{S}_t &= \bar{w}_{1,t}^{(2)} S_{1t} + \bar{w}_{2,t}^{(2)} S_{2t} \\ &= \bar{w}_{1,t}^{(2)} (1,121 S_{t-12} + 21,430) + \bar{w}_{2,t}^{(2)} (1,113 S_{t-12} + 114,900) \end{aligned}$$

Noise:

$$\begin{aligned}\hat{N}_t^* &= \bar{w}_{1,t}^{(3)} N_{1t}^* + \bar{w}_{2,t}^{(3)} N_{2t}^* \\ &= \bar{w}_{1,t}^{(3)} (0,765N_{t-2}^* + 1099) + \bar{w}_{2,t}^{(3)} (0,242N_{t-2}^* + 59,980).\end{aligned}$$

Model *seasonality* dan *noise* lebih sederhana karena menggunakan 1 *input* dan fungsi keanggotaan 2 sehingga hanya ada 2 *rule* yang terbentuk.

Hasil ramalan metode hibrida SSA-ANFIS merupakan jumlahan dari hasil ramalan ANFIS kelompok *trend*, *seasonality* dan *noise* sehingga model ramalan SSA-ANFIS untuk pecahan *inflow* Rp 100.000,00 yaitu:

$$\hat{Y}_t = \hat{T}_t + \hat{S}_t + \hat{N}_t^*$$

dengan:

$$\begin{aligned}\hat{T}_t &= \bar{w}_{1,t}^{(1)} T_{1t} + \bar{w}_{2,t}^{(1)} T_{2t} + \bar{w}_{3,t}^{(1)} T_{3t} + \bar{w}_{4,t}^{(1)} T_{4t} \\ &= \bar{w}_{1,t}^{(1)} (1,114T_{t-1} - 0,100T_{t-5} + 1,518) + \bar{w}_{2,t}^{(1)} (-1,678T_{t-1} \\ &\quad + 3,736T_{t-5} - 55,900) + \bar{w}_{3,t}^{(1)} (6,916T_{t-1} - 7,116T_{t-5} - 51,930) \\ &\quad + \bar{w}_{4,t}^{(1)} (0,930T_{t-1} + 0,084T_{t-5} + 107,200), \\ \hat{S}_t &= \bar{w}_{1,t}^{(2)} S_{1t} + \bar{w}_{2,t}^{(2)} S_{2t} \\ &= \bar{w}_{1,t}^{(2)} (1,121S_{t-12} + 21,430) + \bar{w}_{2,t}^{(2)} (1,113S_{t-12} + 114,900), \\ \hat{N}_t^* &= \bar{w}_{1,t}^{(3)} N_{1t}^* + \bar{w}_{2,t}^{(3)} N_{2t}^* \\ &= \bar{w}_{1,t}^{(3)} (0,765N_{t-2}^* + 1099) + \bar{w}_{2,t}^{(3)} (0,242N_{t-2}^* + 59,980), \\ \bar{w}_{g,t} &= \frac{w_{g,t}}{\sum_g w_{g,t}}, \\ g &= \text{jumlah rule yang terbentuk,} \\ t &= \text{periode, } t = 1, 2, \dots, N.\end{aligned}$$

Selanjutnya disajikan perhitungan manual untuk peramalan *inflow* Rp 100.000,00 pada bulan Januari 2014 ($t=133$). Langkah yang ditempuh yaitu menentukan *output* dari kelima *layer* pada masing-masing kelompok. *Output layer* 1 berupa derajat keanggotaan yang didapatkan dari mensubstitusikan nilai variabel *input* pada fungsi keanggotaan yang terpilih yaitu *Gaussian* untuk

trend dan *noise* serta fungsi *Phi* untuk *seasonality*. Diketahui bahwa *input* untuk masing-masing kelompok pada hasil dekomposisi SSA yaitu:

Trend:

$$\begin{aligned} T_{132} &= 19859,130 \\ T_{128} &= 18667,965 \end{aligned}$$

Seasonality:

$$S_{121} = 8761,695$$

Noise:

$$N_{131}^* = 2623,514.$$

Hasil dekomposisi SSA beserta hasil ramalan ANFIS masing-masing kelompok pada pecahan *inflow* Rp 100.000,00 dapat diperiksa pada Lampiran 13.

Derajat keanggotaan tiap variabel *input* disajikan dalam persamaan-persamaan fungsi keanggotaannya.

Trend:

$$\begin{aligned} \mu_{A1}(T_{t-1}) &= \mu_{A1}(T_{132}) = e^{\frac{-(T_{132}-2984)^2}{2(7034)^2}} = e^{\frac{-(19859,130-2984)^2}{2(7034)^2}} = 0,056 \\ \mu_{A2}(T_{t-1}) &= \mu_{A2}(T_{132}) = e^{\frac{-(T_{132}-19550)^2}{2(7034)^2}} = e^{\frac{-(19859,130-19550)^2}{2(7034)^2}} = 0,999 \\ \mu_{B1}(T_{t-5}) &= \mu_{B1}(T_{128}) = e^{\frac{-(T_{128}-2984)^2}{2(6522)^2}} = e^{\frac{-(18667,965-2984)^2}{2(6522)^2}} = 0,055 \\ \mu_{B2}(T_{t-5}) &= \mu_{B2}(T_{128}) = e^{\frac{-(T_{128}-18340)^2}{2(6522)^2}} = e^{\frac{-(18667,965-18340)^2}{2(6522)^2}} = 0,999 \end{aligned}$$

Seasonality:

$$\begin{aligned} \mu_{A1}(S_{t-12}) &= \mu_{A1}(S_{133-12}) = \mu_{A1}(S_{121}) = \mu_{A1}(8761,695) = 0 \\ \mu_{A2}(S_{t-12}) &= \mu_{A2}(S_{133-12}) = \mu_{A2}(S_{121}) = \mu_{A2}(8761,695) = 1 \end{aligned}$$

Noise:

$$\begin{aligned} \mu_{A1}(N_{t-2}^*) &= \mu_{A1}(N_{131}^*) = e^{\frac{-(N_{131}^*+6454)^2}{2(8355)^2}} = e^{\frac{-(2623,514+6454)^2}{2(8355)^2}} = 0,553 \\ \mu_{A2}(N_{t-2}^*) &= \mu_{A2}(N_{131}^*) = e^{\frac{-(N_{131}^*-13220)^2}{2(8355)^2}} = e^{\frac{-(2623,514-13220)^2}{2(8355)^2}} = 0,447 \end{aligned}$$

Setelah didapatkan *output* dari *layer* 1 berupa derajat keanggotaan, selanjutnya dilakukan perhitungan *output layer 2* yaitu *firing strength*.

Trend:

$$w_{1,133}^{(1)} = \mu_{A1}(T_{132}) \times \mu_{B1}(T_{128}) = 0,056 \times 0,055 = 0,003$$

$$w_{2,133}^{(1)} = \mu_{A1}(T_{132}) \times \mu_{B2}(T_{128}) = 0,056 \times 0,999 = 0,056$$

$$w_{3,133}^{(1)} = \mu_{A2}(T_{132}) \times \mu_{B1}(T_{128}) = 0,999 \times 0,055 = 0,055$$

$$w_{4,133}^{(1)} = \mu_{A2}(T_{132}) \times \mu_{B2}(T_{128}) = 0,999 \times 0,999 = 0,998$$

Seasonality:

$$w_{1,133}^{(2)} = \mu_{A1}(S_{121}) = 0$$

$$w_{2,133}^{(2)} = \mu_{A2}(S_{121}) = 1$$

Noise:

$$w_{1,133}^{(3)} = \mu_{A1}(N_{131}^*) = 0,554$$

$$w_{2,133}^{(3)} = \mu_{A2}(N_{131}^*) = 0,447$$

Pada *layer 3*, *firing strength* dinormalisasi.

Trend:

$$\bar{w}_{1,133}^{(1)} = \frac{w_{1,133}^{(1)}}{w_{1,133}^{(1)} + w_{2,133}^{(1)} + w_{3,133}^{(1)} + w_{4,133}^{(1)}} = \frac{0,003}{1,113} = 0,003$$

$$\bar{w}_{2,133}^{(1)} = \frac{w_{2,133}^{(1)}}{w_{1,133}^{(1)} + w_{2,133}^{(1)} + w_{3,133}^{(1)} + w_{4,133}^{(1)}} = \frac{0,056}{1,113} = 0,051$$

$$\bar{w}_{3,133}^{(1)} = \frac{w_{3,133}^{(1)}}{w_{1,133}^{(1)} + w_{2,133}^{(1)} + w_{3,133}^{(1)} + w_{4,133}^{(1)}} = \frac{0,055}{1,113} = 0,050$$

$$\bar{w}_{4,133}^{(1)} = \frac{w_{4,133}^{(1)}}{w_{1,133}^{(1)} + w_{2,133}^{(1)} + w_{3,133}^{(1)} + w_{4,133}^{(1)}} = \frac{0,998}{1,113} = 0,897$$

Seasonality:

$$\bar{w}_{1,133}^{(2)} = \frac{w_{1,133}^{(2)}}{w_{1,133}^{(2)} + w_{2,133}^{(2)}} = \frac{0}{1} = 0, \quad \bar{w}_{2,133}^{(2)} = \frac{w_{2,133}^{(2)}}{w_{1,133}^{(2)} + w_{2,133}^{(2)}} = \frac{1}{1} = 1$$

Noise:

$$\begin{aligned}\bar{w}_{1,133}^{(3)} &= \frac{w_{1,133}^{(3)}}{w_{1,133}^{(3)} + w_{2,133}^{(3)}} = \frac{0,554}{1,002} = 0,553 \\ \bar{w}_{2,133}^{(3)} &= \frac{w_{2,133}^{(3)}}{w_{1,133}^{(3)} + w_{2,133}^{(3)}} = \frac{0,447}{1,002} = 0,447\end{aligned}$$

Selanjutnya pada *layer 5* dilakukan perhitungan *output* ANFIS untuk masing-masing kelompok.

Trend:

$$\begin{aligned}\hat{T}_{133} &= \bar{w}_{1,133}^{(1)}T_{1,133} + \bar{w}_{2,133}^{(1)}T_{2,133} + \bar{w}_{3,133}^{(1)}T_{3,133} + \bar{w}_{4,133}^{(1)}T_{4,133} \\ &= \bar{w}_{1,133}^{(1)}(1,114T_{132} - 0,100T_{128} + 1,518) + \bar{w}_{2,133}^{(1)}(-1,678T_{132} \\ &\quad + 3,736T_{128} - 55,900) + \bar{w}_{3,133}^{(1)}(6,916T_{132} - 7,116T_{128} - 51,930) \\ &\quad + \bar{w}_{4,133}^{(1)}(0,9303T_{132} + 0,0837T_{128} + 107,200) \\ &= 0,003[1,114(19859,13) - 0,100(18667,96) + 1,518] \\ &\quad + 0,051[-1,678(19859,13) + 3,736(18667,96) + -55,900] \\ &\quad + 0,050[6,916(19859,13) - 7,116(18667,96) - 51,930] \\ &\quad + 0,897[0,9303(19859,13) + 0,0837(18667,96) + 107,200] \\ &= 20182,133\end{aligned}$$

Seasonality:

$$\begin{aligned}\hat{S}_{133} &= \bar{w}_{1,133}^{(2)}S_{1,133} + \bar{w}_{2,133}^{(2)}S_{2,133} \\ &= \bar{w}_{1,133}^{(2)}(1,121S_{121} + 21,430) + \bar{w}_{2,133}^{(2)}(1,113S_{121} + 114,900) \\ &= 0[1,121(8761,695) + 21,430] + 1[1,113(8761,695) + 114,900] \\ &= 9866,667\end{aligned}$$

Noise:


$$\begin{aligned}\hat{N}_{133}^* &= \bar{w}_{1,133}^{(3)}N_{1,133}^* + \bar{w}_{2,133}^{(3)}N_{2,133}^* \\ &= \bar{w}_{1,133}^{(3)}(0,7649N_{131}^* + 1099) + \bar{w}_{2,133}^{(3)}(0,2423N_{131}^* + 59,980) \\ &= 0,553[0,7649(2623,514) + 1099] \\ &\quad + 0,447[0,2423(2623,514) + 59,980] \\ &= 2029,172\end{aligned}$$

Dengan demikian hasil ramalan *inflow* untuk bulan Januari 2014 yaitu:


$$\begin{aligned}\hat{Y}_{133} &= \hat{T}_{133} + \hat{S}_{133} + \hat{N}_{133}^* \\ &= 20182,133 + 9866,667 + 2029,172 \\ &= 32077,972.\end{aligned}$$

Hasil ramalan ANFIS *inflow* bulan Januari 2014 perhitungan manual yaitu 32077,972 miliar rupiah. Hasil ramalan ANFIS pada *output* MATLAB periode 133 untuk *trend* sebesar 20181,628, *seasonality* sebesar 9863,419 sedangkan untuk *noise* sebesar 2029,562 sehingga hasil ramalan total untuk periode 133 sebesar 32074,609. Perbedaan hasil manual dengan *output* disebabkan adanya pembulatan.


Prosedur yang sama untuk mendapatkan hasil ramalan dilakukan pada masing-masing pecahan *inflow* dan *outflow* yang lain. Model ANFIS terbaik dan estimasi parameter untuk pecahan *inflow* dan *outflow* disajikan dalam Lampiran 14 dan 15. Berikut adalah *time series* plot perbandingan data aktual dan hasil ramalan SSA-ANFIS tiap pecahan *inflow* dan *outflow*.




Gambar 4.37 *Time Series* Plot Perbandingan Hasil Peramalan SSA-ANFIS per Pecahan *Inflow* dan *Outflow*



Gambar 4.37 Time Series Plot Perbandingan Hasil Peramalan SSA-ANFIS per Pecahan Inflow dan Outflow (Lanjutan)



Gambar 4.37 Time Series Plot Perbandingan Hasil Peramalan SSA-ANFIS per Pecahan Inflow dan Outflow (Lanjutan)




Gambar 4.37 Time Series Plot Perbandingan Hasil Peramalan SSA-ANFIS per Pecahan Inflow dan Outflow (Lanjutan)

Plot warna merah pada Gambar 4.37 merupakan hasil ramalan SSA-ANFIS pada tiap pecahan sedangkan plot hitam merupakan data aktualnya. Melalui Gambar 4.37 tersebut dapat ditunjukkan bahwa SSA-ANFIS bekerja cukup baik pada peramalan data *in-sample* karena sebagian besar pola data aktual dapat diikuti. Untuk data *out-sample* dapat dilihat bahwa peramalan SSA-ANFIS kurang tepat bahkan pada pecahan *inflow* Rp 20.000,00 dan Rp 2.000,00 hasil ramalan terlihat tidak mengikuti data *out-*


sample. Hal ini dapat disebabkan oleh beberapa faktor diantaranya yaitu peramalan yang digunakan merupakan peramalan 36 tahap ke depan serta penentuan variabel *input* yang kurang tepat. Secara keseluruhan dapat dilihat bahwa SSA-ANFIS memiliki kemampuan hasil ramalan yang belum baik.

4.5 Pemilihan Metode Peramalan Terbaik

Pemilihan metode peramalan terbaik dapat dilakukan dengan melihat kriteria evaluasi model yang digunakan. Dalam penelitian ini digunakan beberapa kriteria evaluasi model. Berikut disajikan plot perbandingan hasil ramalan ARIMAX dan SSA-ANFIS terhadap data *out-sample* pada pecahan *inflow* dan *outflow* uang kartal di Indonesia.



Gambar 4.38 Plot Perbandingan Hasil Peramalan Data *Out-Sample*



Gambar 4.38 Plot Perbandingan Hasil Peramalan Data *Out-Sample* (Lanjutan)

Dapat dilihat pada Gambar 4.38 masing-masing pecahan memiliki pola hasil ramalan yang berbeda-beda. Untuk mengetahui metode mana yang memiliki performa lebih baik pada tiap pecahan, dapat dilihat nilai evaluasi model berdasarkan kriteria RMSE, MAPE, sMAPE dan sMdAPE pada data *out-sample* seperti Tabel 4.36.


Tabel 4.36 Perbandingan Kriteria Evaluasi Model Ramalan ARIMAX dan SSA-ANFIS Setiap Pecahan

Data	Metode	RMSE	MAPE	sMAPE	sMdAPE
<i>Inflow</i>					
Rp 100.000,00	ARIMAX	11222,41	34,94	30,25	24,20
	SSA-ANFIS	11550,03	33,89	30,20	25,49
Rp 50.000,00	ARIMAX	4666,69	21,57	16,35	14,93
	SSA-ANFIS	7331,58	30,42	36,58	29,04
Rp 20.000,00	ARIMAX	414,76	28,91	37,81	22,77
	SSA-ANFIS	327,34	24,42	28,45	19,58
Rp 10.000,00	ARIMAX	308,12	24,58	29,77	26,66
	SSA-ANFIS	205,44	25,68	23,11	24,20
Rp 5.000,00	ARIMAX	186,01	14,43	15,79	9,23
	SSA-ANFIS	183,33	30,28	30,09	28,46
Rp 2.000,00	ARIMAX	131,30	53,49	34,14	34,87
	SSA-ANFIS	81,58	28,78	27,09	23,93
Rp 1.000,00	ARIMAX	25,98	132,99	-308,11	44,84
	SSA-ANFIS	10,46	44,50	33,66	25,89
<i>Outflow</i>					
Rp 100.000,00	ARIMAX	9880,05	34,75	28,27	26,18
	SSA-ANFIS	18126,86	57,71	47,68	34,97
Rp 50.000,00	ARIMAX	5893,42	32,80	24,91	22,69
	SSA-ANFIS	7614,12	35,51	30,60	22,90
Rp 20.000,00	ARIMAX	967,92	273,89	78,13	63,68
	SSA-ANFIS	1010,15	139,30	68,26	66,98
Rp 10.000,00	ARIMAX	731,34	72,00	31,56	23,48
	SSA-ANFIS	822,79	147,70	125,57	79,86
Rp 5.000,00	ARIMAX	666,34	83,24	52,94	50,60
	SSA-ANFIS	507,60	160,98	2797,18	72,37
Rp 2.000,00	ARIMAX	293,10	86,30	0,73	34,00
	SSA-ANFIS	409,54	185,62	82,26	90,06
Rp 1.000,00	ARIMAX	116,27	2697,26	-310,90	-222,78
	SSA-ANFIS	27,00	405,04	49,99	92,04


Dengan melakukan perbandingan seperti pada Tabel 4.36 dapat dilihat bahwa metode terbaik merupakan metode dengan nilai RMSE, MAPE, sMAPE atau sMdAPE terkecil. Jika metode terbaik yang ditunjukkan tiap nilai evaluasi berbeda maka pemilihan metode terbaik didasarkan pada banyaknya nilai evaluasi yang menyatakan bahwa metode tersebut adalah metode terbaik. Jika jumlah keduanya sama, maka dipilih mengikuti kriteria RMSE *out-sample*. Dengan demikian didapatkan hasil

bahwa metode SSA-ANFIS merupakan metode terbaik untuk meramalkan 6 pecahan yaitu *inflow* Rp 100.000,00, Rp 20.000,00, Rp 10.000,00, Rp 2.000,00, Rp 1.000,00 dan pecahan *outflow* Rp 1.000,00. Sedangkan untuk ke-9 pecahan lainnya lebih baik diramalkan dengan metode ARIMAX. Hal tersebut menunjukkan bahwa SSA-ANFIS belum dapat bekerja secara optimal pada keseluruhan pecahan *inflow* dan *outflow*.

Untuk mengetahui seberapa kuat hasil ramalan yang ditunjukkan dengan metode terpilih baik ARIMAX maupun SSA-ANFIS dapat dilihat plot RMSE *adaptive* pada hasil ramalan seperti pada Gambar 4.39 berikut.



Gambar 4.39 Plot RMSE *Adaptive* Tiap Pecahan *Inflow* dan *Outflow* Uang Kartal



Gambar 4.39 Plot RMSE Adaptive Tiap Pecahan Inflow dan Outflow Uang Kartal (Lanjutan)

Melalui Gambar 4.39 dapat diketahui bahwa pada pecahan Rp 100.000,00 nilai RMSE sampai periode ke 7 tidak mengalami kenaikan bahkan turun, namun setelah periode 7 terjadi kenaikan yang cukup signifikan pada nilai RMSE sehingga model terbaik pada pecahan *inflow* Rp 100.000,00 baik digunakan untuk meramalkan 7 periode ke depan. Periode ramalan untuk pecahan yang lain, dapat ditunjukkan pada Tabel 4.37.


Tabel 4.37 Periode Ramalan Terbaik Berdasarkan RMSE *Adaptive*

Data	Pecahan	Periode	Data	Pecahan	Periode
<i>Inflow</i>	Rp 50.000,00	7	<i>Outflow</i>	Rp 100.000,00	2
	Rp 20.000,00	7		Rp 50.000,00	2
	Rp 10.000,00	7		Rp 20.000,00	7
	Rp 5.000,00	7		Rp 10.000,00	6
	Rp 2.000,00	7		Rp 5.000,00	6
	Rp 1.000,00	7		Rp 2.000,00	7
				Rp 1.000,00	14


Dapat dilihat pada Tabel 4.37 bahwa pecahan *outflow* Rp 1.000,00 memiliki periode peramalan tertinggi. Hal ini dikarenakan nilai RMSE yang ditunjukkan pada gambar sebelumnya terus mengalami penurunan sampai periode ke-14.

4.6 Peramalan dengan Metode Terbaik


Setelah didapatkan metode peramalan terbaik, berikut ini disajikan plot hasil ramalan 36 periode ke depan pada masing-masing pecahan *inflow* dan *outflow* uang kartal di Indonesia.



Gambar 4.40 Hasil Peramalan *Inflow* dan *Outflow* Uang Kartal di Indonesia dengan Metode Terbaik



Gambar 4.40 Hasil Peramalan *Inflow* dan *Outflow* Uang Kartal di Indonesia dengan Metode Terbaik



Gambar 4.40 Hasil Peramalan *Inflow* dan *Outflow* Uang Kartal di Indonesia dengan Metode Terbaik (Lanjutan)


Plot hitam yang ditunjukkan Gambar 4.40 merupakan plot data *inflow* dan *outflow* aktual sampai dari bulan Januari tahun 2011 sampai bulan Desember tahun 2016 sedangkan *plot* merah merupakan hasil ramalan berdasarkan metode terbaik selama 3 tahun ke depan. Garis putus-putus biru merupakan batas antara data dengan hasil ramalan. Dapat dilihat bahwa kecenderungan *inflow* dan *outflow* uang kartal tinggi pada bulan-bulan tertentu menunjukkan bahwa hasil peramalan masih menangkap adanya variasi kalender. Baik pada hasil ramalan *inflow* maupun *outflow*, untuk variasi kalender yaitu terjadinya hari raya Idul Fitri cenderung mengalami kenaikan dari tahun-tahun sebelumnya. Namun untuk pecahan *inflow* dan *outflow* Rp 1.000,00 cenderung mengalami penurunan. Hal ini mengindikasikan bahwa semakin lama pecahan uang Rp 1.000,00 semakin jarang digunakan oleh masyarakat. Hasil ramalan *inflow* dan *outflow* secara tertulis dapat dilihat pada Lampiran 16 dan 17.

Selanjutnya disajikan RMSE yang dihasilkan dari data *in-sample* untuk model pada Gambar 4.40 dan dibandingkan dengan standar deviasi masing-masing pecahan *inflow* dan *outflow* uang kartal. Satuan yang digunakan adalah miliar rupiah.

Tabel 4.38 Perbandingan RMSE Model dan Standar Deviasi

Data	Pecahan	RMSE in-sample	St.dev	Kemampuan Mereduksi (%)
<i>Inflow</i>	Rp 100.000,00	5905,057	10836,331	45,507
	Rp 50.000,00	2995,819	5724,940	47,671
	Rp 20.000,00	148,256	486,058	69,498
	Rp 10.000,00	84,431	251,974	66,492
	Rp 5.000,00	72,585	203,986	64,417
	Rp 2.000,00	42,501	114,778	62,972
	Rp 1.000,00	13,690	70,112	80,474
<i>Outflow</i>	Rp 100.000,00	5039,499	12826,677	60,711
	Rp 50.000,00	4072,429	7027,346	42,049
	Rp 20.000,00	466,842	751,789	37,903
	Rp 10.000,00	306,718	624,413	50,879
	Rp 5.000,00	254,146	592,242	57,087
	Rp 2.000,00	77,953	383,857	79,692
	Rp 1.000,00	46,462	100,675	53,849

Berdasarkan Tabel 4.38 dapat dilihat RMSE model yang dihasilkan lebih kecil dari standar deviasi data. Hal ini menunjukkan bahwa model bekerja dengan baik karena dapat mereduksi standar deviasi dari data. Besarnya kemampuan mereduksi dari masing-masing model pada tiap pecaha *inflow* dan *outflow* dapat divisualisasikan dalam Gambar 4.41.



Gambar 4.41 Grafik Besarnya Standar Deviasi yang Direduksi pada Masing-Masing Model Pecahan

Gambar 4.41 menunjukkan bahwa Y_7 yaitu model ramalan pada pecahan *inflow* Rp 1.000,00 memiliki kemampuan reduksi tertinggi yang mencapai 80%. Kemudian Y_{13} yaitu pecahan *outflow* Rp 2.000,00 juga memiliki kemampuan mereduksi standar deviasi dari data hampir 80%. Secara keseluruhan model dapat mereduksi standar deviasi dengan cukup baik karena sebagian besar pecahan memiliki nilai lebih dari 50%.

(Halaman ini sengaja dikosongkan)

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis yang telah dilakukan, dapat diambil 5 kesimpulan penelitian ini.

1. Kajian simulasi terhadap metode SSA-ANFIS menunjukkan bahwa SSA mampu menangkap pola variasi kalender yaitu ditangkap dalam pola musiman. Metode peramalan SSA-ANFIS secara agregat memiliki peforma yang lebih baik daripada peramalan secara individu. Peramalan SSA-ANFIS dapat diterapkan pada jenis data yang memiliki *noise random* maupun tidak *random*.
2. Model ARIMAX mampu menangkap adanya variasi kalender hari raya Idul Fitri. Model tersebut sudah mengikuti pola data aktual *in-sample* dengan baik, namun untuk data *out-sample* hasil ramalan model ARIMAX masih memiliki beberapa kesalahan. Peramalan interval dapat memuat keseluruhan data *out-sample* pecahan *outflow* Rp 20.000,00 dan Rp 1.000,00 serta sudah memuat sebagian besar data *out-sample* pecahan yang lain.
3. Dalam peramalan menggunakan SSA-ANFIS, salah satu komponen penting yang dapat memengaruhi akurasi peramalan adalah pemilihan *input* yang digunakan. Pemilihan *input* dapat dilakukan berdasarkan *lag* signifikan pada plot PACF data stasioner. Model SSA-ANFIS bekerja dengan baik untuk meramalkan data *in-sample* karena peramalan yang digunakan merupakan peramalan satu tahap ke depan sedangkan peramalan untuk data *out-sample* terlihat kurang baik karena peramalan yang dilakukan merupakan peramalan *k* tahap ke depan.
4. Hasil perbandingan metode SSA-ANFIS dengan ARIMAX menyatakan bahwa metode SSA-ANFIS memiliki peforma yang baik pada peramalan 6 pecahan yaitu *inflow* Rp

100.000,00, Rp 20.000,00, Rp 2.000,00, Rp 1.000,00 dengan kekuatan peramalan 7 periode ke depan dan pecahan *outflow* Rp 1.000,00 dengan kekuatan ramalan sampai 14 periode ke depan. Dengan demikian dapat digeneralisasi bahwa pada peramalan pecahan *inflow*, SSA-ANFIS lebih baik dari ARIMAX.

5. Hasil peramalan dengan metode terbaik menunjukkan kecenderungan *inflow* dan *outflow* tiap pecahan pada hari raya Idul Fitri mengalami kenaikan, namun untuk pecahan *inflow* dan *outflow* Rp 1.000,00 cenderung menurun. Hal ini mengindikasikan bahwa semakin lama pecahan uang Rp 1.000,00 semakin jarang digunakan oleh masyarakat.

5.2 Saran

Saran yang dapat diberikan pada penelitian selanjutnya yaitu dalam memilih variabel *input* untuk proses ANFIS sebaiknya dilakukan alternatif metode lain misalnya dengan melihat *lag* yang signifikan pada proses ARIMA dari data tersebut. Alternatif lainnya yaitu dengan pengujian *Lagrange Multiplier* untuk mengetahui seberapa besar kontribusi variabel *input* terhadap data asli sehingga dapat memberikan hasil ramalan yang lebih baik. Sebaiknya peneliti berhati-hati saat mengelompokkan *eigentriple* pada metode SSA dikarenakan pengelompokan yang kurang tepat akan mempengaruhi hasil pemodelan ANFIS.

DAFTAR PUSTAKA

- Abdollahzade, M., Miranian, A., Hassani, H., & Iranmanesh, H. (2015). A New Hybrid Enhanced Local Linier Neuro Fuzzy Model Based on The Optimize Singular Spectrum Analysis and Its Application for Nonlinear and Chaotic Time Series Forecasting. *Information Sciences*, 295, 107-125.
- Amstrong, J. S. (1983). Relative Accuracy of Judgemental and Extrapolative Methods in Forecasting Annual Earnings. *Journal of Forecasting*, 2, 437-447.
- Azalia, I., Susilaningrum, D., & Suhartono. (2016). *Peramalan Kebutuhan Energi Listrik Bulanan di Gresik, Jawa Timur Menggunakan Metode Autoregressive Integrated Moving Average, Adaptive Beuro Fuzzy Inference System dan Fungsi Transfer*. Tugas Akhir, Institut Teknologi Sepuluh Nopember, Departemen Statistika, Surabaya.
- Bank Indonesia. (2013). *Kodifikasi Peraturan Bank Indonesia : Liquiditas Rupiah Laporan Berkala*. Jakarta: Bank Indonesia.
- Bank Indonesia. (2017). *Kamus Bank Indonesia*. Jakarta: Bank Indonesia.
- Bank Indonesia. (2017). *Publikasi : Perkembangan Uang Beredar*. Jakarta: Bank Indonesia.
- Box, G., & Cox, D. R. (1964). An Analysis of Transformations. *Journal of The Royal Statistical Society*, 211-252.
- Cryer, J. D., & Chan, K. S. (2008). *Time Series Analysis with Applications in R*. New York: Springer Science.
- Ete, A. A., Suharsono, A., & Suhartono. (2017). *Peramalan Jumlah Kedatangan Wisatawan Mancanegara Menurut Pintu Masuk Menggunakan Singular Spectrum Analysis dan ARIMA*. Tesis, Institut Teknologi Sepuluh Nopember, Institut Teknologi Sepuluh Nopember, Departemen Statistika, Surabaya.

- Golyandina, N., & Zhigljavsky, A. (2013). *Singular Spectrum Analysis for Time Series*. New York: Springer.
- Gujarati, D. N. (2003). *Basic Econometrics* (4th ed.). New York, USA: McGraw-Hill.
- Hamilton, J. D. (1994). *Time Series Analysis*. New Jersey: Princeton University Press.
- Hassani, H., Webster, A., Silva, S. E., & Heravi, S. (2015). Forecasting U.S. Tourist Arrivals Using Optimal Singular Spectrum Analysis. *Tourism Management*, 46, 322-335.
- Ikoku, A. (2014). Modeling and Forecasting Currency in Circulation for Liquidity Management in Nigeria. *CBN Journal of Applied Statistics*, 5, 1, 79-104.
- Jang, J. S. (1993). ANFIS : Adaptive Network-Based-Fuzzy Inference Systems. *IEEE Trans Sys Man Cybern*, 23, 3, 665-685.
- Kusumadewi, S., & Hartati, S. (2013). *Neuro-Fuzzy : Integrasi Sistem Fuzzy dan Jaringan Syaraf*. Yogyakarta: Graha Ilmu.
- Lee, M. H., Suhartono, & Hamzah, N. A. (2010). Calendar variation model based on ARIMAX for forecasting sales data with Ramadhan effect. *Regional Conference on Statistical Sciences*, 349-361.
- Li, H., Cui, L., & Guo, S. (2014). A Hybrid Short-Term Power Load Forecasting Model Based on. *Hindawi : Advances in Electrical Engineering*.
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: Results, Conclusions and Implications. *International Journal of Forecasting*, 451-476.
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting : Methods and Applications* (3rd ed.). USA: John Wiley and Sons.
- Nguyen, V., Li, Q., & Nguyen, L. (2017). Drought Forecasting Using ANFIS- A Case Study in Drought Prone Area of Vietnam. *Paddy and Water Environment*, 5(3), 605-616.
- Nopirin. (1990). *Ekonomi Moneter*. Yogyakarta: BPFE.

- Piri, J., & Kisi, O. (2015). Modelling Solar Radiation Reached to The Earth Using ANFIS, NN-ARX, and Empirical Models (Case Studie: XZahedan and Bojnurd Stationst). *Journal of Atmospheric and Solar-Terrestrial Physics*, 123, 39-47.
- Rencher, A. (2002). *Methods of Multivariate Analysis* (2nd ed.). New York: John Wiley and Sonc, Inc.
- Safitri, R., Setiawan, & Ahmad, I. S. (2016). Peramalan Outflow Uang Pecahan di Jawa Timur Menggunakan Generalized Space Time Autoregressive (GSTAR). *Jurnal Sains dan Seni ITS*, 5, 2, 2337-3520.
- Saputri, P. D. (2017). *Aplikasi Model Hybrid Quantile Regression Neural Network Pada Peramalan Pecahan Inflow dan Outflow Uang Kartal di Indonesia*. Tugas Akhir, Institut Teknologi Sepuluh Nopember , Departemen Statistika, Surabaya.
- Solikin, & Suseno. (2002). *Pengertian, Penciptaan dan Peranan Uang dalam Perekonomian*. Jakarta: Pusat Pendidikan dan Studi Kebanksentralan (PPSK).
- Suparta, W., & Alhasa, K. M. (2016). *Modeling of Tropospheric Delays Using ANFIS*. Netherlands: Springer Internasional.
- Susanti, A., & Suhartono. (2016). *Model Hibrida Exponential Smoothing Pendekatan State Space dengan Metode Variasi Kalender untuk Peramalan Inflow dan Outflow Uang Kartal di Jawa Timur*. Tugas Akhir, Institut Teknologi Sepuluh Nopember, Departemen Statistika, Surabaya.
- Sutawjaya, A., & Zulfahmi. (2014). *Analisis Perilaku Inflasi Jangka Pendek dan Jangka Panjang atas Faktor-Faktor Penyebab Utama di Indonesia*. Universitas Terbuka, Fakultas Ekonomi.
- Wei, W. W. (2006). *Time Series Analysis Univariate and Multivariate Methods* (2nd ed.). United States of America: Pearson Education, Inc.
- Wulansari, R. E., Setiawan, & Suhartono. (2017). *Peramalan Outflow Tiap Pecahan Uang Kartal dengan Metode ARIMAX, Hybrid ARIMAX-ANN, dan VARI-X (Studi Kasus*

- Bank Indonesia Regional Surabaya*). Tesis, Institut Teknologi Sepuluh Nopember, Departemen Statistika, Surabaya.
- Xiao, Y., Liu, J. J., Hu, Y., Wang, Y., Lai, K. K., & Wang, S. (2014). A Neuro-Fuzzy Combination Model Based on Singular Spectrum Analysis for Air Transport Demand Forecasting. *Journal of Air Transport Management*, 39, 1-11.
- Zhang, Q., Wang, B. D., He, B., Peng, Y., & Ren, M. L. (2011). Singular Spectrum Analysis and ARIMA Hybrid Model. *Water Resour Manage*, 25, 2683-2703.
- Zhang, Z., Song, Y., Liu, F., & Liu, J. (2016). Daily Average Wind Power Interval Forecasts Based on an Optimal Adaptive-Network-Based Fuzzy Inference System and Singular Spectrum Analysis. 8, 125.
- Zounemart-Kermani, M., & Teshnehlab, M. (2008). Using Adaptive Neuro-Fuzzy Inference System for Hydrological Time Series Prediction. *Applied Soft Computing*, 8, 928-936.

LAMPIRAN

Lampiran 1 Data *Inflow* dan *Outflow* di Indonesia

<i>Inflow</i> (miliar Rp)								
Tahun	Bulan	1.000	2.000	5000	10.000	20.000	50.000	100.000
2003	Januari	278,244	0,000	551,858	952,163	2096,296	12424,344	7666,245
2003	Februari	187,763	0,000	344,548	610,315	1399,736	8616,926	5308,464
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015	November	18,625	337,163	533,887	657,349	663,971	14425,381	18856,685
2015	Desember	15,893	239,940	421,428	569,740	614,987	10632,061	13436,752
2016	Januari	17,933	224,858	492,776	713,442	797,266	27297,007	47141,781
2016	Februari	18,499	234,338	498,198	690,416	769,849	17300,484	27622,141
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016	November	15,547	330,043	544,501	682,070	778,572	15030,069	22409,779
2016	Desember	478,174	568,097	657,851	13001,197	20162,623	13001,197	20162,623
<i>Outflow</i> (miliar Rp)								
2003	Januari	123,186	0,000	286,777	517,170	1192,291	8146,788	5275,028
2003	Februari	101,478	0,000	241,196	429,077	1092,891	8685,145	4274,460
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2015	November	3,199	120,876	209,522	386,563	498,633	14840,341	25280,419
2015	Desember	4,518	266,222	527,925	856,617	1049,066	29327,246	53484,049
2016	Januari	2,382	206,569	373,200	728,848	842,464	7867,459	8302,630
2016	Februari	2,283	134,584	231,286	400,095	505,229	12009,425	16450,722
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016	November	2,844	134,953	229,844	427,907	474,291	16104,669	30681,523
2016	Desember	13,145	344,542	637,670	1054,799	1146,138	24550,124	52448,688

Lampiran 2 Surat Pernyataan Penggunaan Data Sekunder

SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika FMKSD ITS:

Nama : Zuhrofatul Ulwiyah

NRP : 1314 100 095

menyatakan bahwa data yang digunakan dalam Tugas Akhir/ ~~Thesis~~ ini merupakan data sekunder yang diambil dari penelitian / buku/ Tugas Akhir/ ~~Thesis/ publikasi lainnya~~ yaitu:

Sumber : Priliyandari Dina Saputri, Statistika FMKSD ITS

Keterangan : Data *Inflow* dan *Outflow* Nasional Per Pecahan Tahun 2003 - 2016

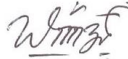
Surat Pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Mengetahui
Pembimbing Tugas Akhir

Surabaya, 15 Januari 2018



(Imam Safawi Ahmad, M.Si)
NIP. 19810224 201404 1 001



(Zuhrofatul Ulwiyah)
NRP. 1314 100 095

*(coret yang tidak perlu)

Lampiran 3 Perbandingan RMSE *Out-Sample* Tiap *Eigentriple* pada Skenario Kedua

<i>Eigentriple</i>	Fungsi Keanggotaan	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>	<i>Eigentriple</i>	Fungsi Keanggotaan	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
1	<i>Trapezoidal</i>	0,207	0,204	0,275	7	<i>Trapezoidal</i>	3,231	1,051	1,189
	<i>Gaussian</i>	0,473	0,283	1,249		<i>Gaussian</i>	3,225	1,076	1,241
	<i>Phi</i>	0,207	0,244	0,308		<i>Phi</i>	3,223	1,040	1,206
	<i>Generalized Bell</i>	0,441	0,755	1,535		<i>Generalized Bell</i>	3,230	1,057	2,573
2	<i>Trapezoidal</i>	4,187	0,716	-	8	<i>Trapezoidal</i>	2,216	0,243	0,270
	<i>Gaussian</i>	4,182	0,709	-		<i>Gaussian</i>	2,213	0,244	0,279
	<i>Phi</i>	4,193	0,753	-		<i>Phi</i>	2,216	0,252	0,282
	<i>Generalized Bell</i>	4,187	0,772	-		<i>Generalized Bell</i>	2,221	0,252	0,274
3	<i>Trapezoidal</i>	3,596	0,691	0,649	9	<i>Trapezoidal</i>	1,929	0,578	0,514
	<i>Gaussian</i>	3,592	0,720	0,643		<i>Gaussian</i>	1,928	0,543	0,511
	<i>Phi</i>	3,596	0,692	0,648		<i>Phi</i>	1,929	0,552	0,517
	<i>Generalized Bell</i>	3,593	0,702	0,642		<i>Generalized Bell</i>	1,929	0,575	0,509
4	<i>Trapezoidal</i>	3,065	0,923	0,924	10	<i>Trapezoidal</i>	1,076	0,440	0,431
	<i>Gaussian</i>	3,119	0,918	0,930		<i>Gaussian</i>	1,076	0,567	0,406
	<i>Phi</i>	3,108	0,955	0,931		<i>Phi</i>	1,075	0,522	0,441
	<i>Generalized Bell</i>	3,117	0,915	0,927		<i>Generalized Bell</i>	1,077	0,491	0,363
5	<i>Trapezoidal</i>	2,536	0,876	-	11	<i>Trapezoidal</i>	1,460	0,250	0,225
	<i>Gaussian</i>	2,535	0,521	-		<i>Gaussian</i>	1,447	0,281	0,268
	<i>Phi</i>	2,576	0,814	-		<i>Phi</i>	1,451	0,269	0,480
	<i>Generalized Bell</i>	2,547	0,548	-		<i>Generalized Bell</i>	1,448	0,285	0,274
6	<i>Trapezoidal</i>	4,558	2,560	1,329	<i>Noise</i>	<i>Trapezoidal</i>	3,849	4,011	4,383
	<i>Gaussian</i>	4,558	2,171	516,483		<i>Gaussian</i>	3,833	3,939	4,570
	<i>Phi</i>	4,551	2,491	2,033		<i>Phi</i>	3,877	4,095	4,302
	<i>Generalized Bell</i>	4,553	2,429	2,016		<i>Generalized Bell</i>	3,867	4,027	4,383

Lampiran 4 Syntax ARIMAX untuk Data *Inflow* Pecahan Rp 100.000,00 (dengan SAS)

```

data inflow;
input y t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 v1 v2 v3 v4 v11 v21 v31
      v41;
datalines;

7666.24463 1 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0
5308.4639 2 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
5134.96445 3 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
5760.193725 4 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
5429.6734 5 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
5610.13055 6 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0
6480.616725 7 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0
5883.57475 8 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0
6091.1952 9 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0
6408.24315 10 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0
      :
17271.3308 131 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0
9995.2147 132 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0
. 133 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
. 134 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
. 135 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
. 136 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
      :
. 167 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0
. 168 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0
;

proc arima data=inflow;
identify var=y(1,12) crosscorr=(t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 v1
v2 v3 v4 v11 v21 v31 v41) nlag=36;
run;
estimate p=(0) q=(1,12) input=(t M1 M2 M3 M4 M5 M6 M7 M8 M9 M10 M11 M12 v1
v2 v3 v4 v11 v21 v31 v41) noconstant method=ml;
forecast lead=36 out=out2 printall;
run;
proc univariate data=out2 normal;
var residual;
run;

proc export data=work.out2
outfile='E:/KULIAH/SMT 7/Tugas Akhir/ARIMAX/i100k.xls'
dbms=excel
replace;
run;

```


[illegible]

(ii). Plot PACF setelah *differencing lag-1*

[illegible]

5b. Identifikasi Orde ARIMAX Pecahan *Inflow* Rp 20.000,00

(i). Plot ACF setelah *differencing lag-1* dan *lag-12*

Autocorrelations				
Lag	Covariance	Correlation	-1	9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1
0	88798.620	1.00000		*****
1	-48941.563	-.55115		*****
2	-2846.402	-.03205		*****
3	15799.870	0.17793		*****
4	-6928.385	-.07802		*****
5	-1224.149	-.01379		*****
6	3784.814	0.04262		*****
7	-3932.002	-.04428		*****
8	-1055.462	-.01189		*****
9	9919.277	0.11171		*****
10	-5557.570	-.06259		*****
11	-10367.872	-.11676		*****
12	22622.479	0.25476		*****
13	-19311.466	-.21747		*****
14	3850.316	0.04336		*****
15	3660.021	0.04122		*****
16	-4570.128	-.05147		*****
17	1998.177	0.02250		*****
18	4625.116	0.05209		*****
19	-6683.501	-.07527		*****
20	6371.024	0.07175		*****
21	-5052.965	-.05690		*****
22	-8691.324	-.09788		*****
23	20123.385	0.22662		*****
24	-11626.343	-.13093		*****
25	-4467.052	-.05031		*****
26	9766.757	0.10999		*****
27	-2438.121	-.02746		*****
28	-4331.060	-.04877		*****
29	4886.107	0.05502		*****
30	-2915.025	-.03283		*****
31	-756.716	-.00852		*****
32	4052.043	0.04563		*****
33	-4407.361	-.04963		*****
34	-6416.216	-.07226		*****
35	21735.944	0.24478		*****
36	-22182.964	-.24981		*****

[illegible]

(ii). Plot PACF setelah *differencing lag-1*

[illegible]

(ii). Plot PACF

[illegible]

[illegible]

(ii). Plot PACF

Partial Autocorrelations		-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
Lag	Correlation																					
1	0.78085																					
2	-0.13719																					
3	0.07431																					
4	-0.05007																					
5	0.07518																					
6	-0.00916																					
7	0.14458																					
8	-0.00343																					
9	0.11472																					
10	0.06484																					
11	0.32506																					
12	-0.26923																					
13	-0.39125																					
14	-0.10223																					
15	0.14178																					
16	-0.05429																					
17	-0.01184																					
18	0.02972																					
19	-0.07218																					
20	0.09676																					
21	0.05949																					
22	-0.12456																					
23	-0.03065																					
24	0.01660																					
25	0.03055																					
26	-0.04699																					
27	-0.03322																					
28	0.01711																					
29	-0.10797																					
30	0.03411																					
31	-0.06752																					
32	0.03915																					
33	-0.16387																					
34	0.01057																					
35	-0.00893																					
36	0.00467																					


5f. Identifikasi Orde ARIMAX Pecahan *Inflow* Rp 1.000,00

(i). Plot ACF setelah *differencing lag-1*

[illegible]

(ii). Plot PACF setelah *differencing lag-1*

Partial Autocorrelations																						
Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
1	-0.20053									****	.											
2	-0.15885									***	.											
3	0.11643									.	**											
4	-0.14270									***	.											
5	-0.18533									****	.											
6	-0.08426									**	.											
7	-0.30529									*****	.											
8	-0.18225									****	.											
9	-0.15238									***	.											
10	-0.42755									*****	.											
11	-0.17659									****	.											
12	0.52252									.	*****											
13	0.08556									.	**											
14	0.01129									.	.											
15	-0.10280									.	**											
16	-0.08321									.	**											
17	0.09164									.	**											
18	-0.12300									.	**											
19	-0.09036									.	**											
20	-0.07774									.	**											
21	0.07662									.	**											
22	-0.05686									.	*											
23	0.11245									.	**											
24	-0.05720									.	*											
25	0.03328									.	*											
26	-0.14791									***	.											
27	-0.04395									*	.											
28	0.03791									*	.											
29	-0.10136									**	.											
30	0.07058									.	*	.										
31	0.00292									.	.	.										
32	0.05032									.	*	.										
33	-0.10591									**	.	.										
34	-0.04644									*	.	.										
35	0.00184									.	.	.										
36	-0.00835									.	.	.										



(ii). Plot PACF setelah *differencing lag-1*

[illegible]

5h. Identifikasi Orde ARIMAX Pecahan *Outflow* Rp 50.000,00

(i). Plot ACF setelah *differencing lag-1*

Autocorrelations																								
Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
0	69839253	1.00000																						
1	-37634523	-.53887																						
2	-275788	-.00395																						
3	5603657	0.08024																						
4	1016660	0.01456																						
5	-3808631	-.05453																						
6	-1053985	-.01509																						
7	1575888	0.02256																						
8	-1856103	-.02658																						
9	8780180	0.12572																						
10	-10967332	-.15704																						
11	-11778908	-.16866																						
12	38162888	0.54644																						
13	-26206385	-.37524																						
14	3435664	0.04919																						
15	1945144	0.02785																						
16	4310668	0.06172																						
17	-8432070	-.12074																						
18	2850013	0.04081																						
19	-1156525	-.01656																						
20	40429.480	0.00058																						
21	8709635	0.12471																						
22	-19350908	-.27708																						
23	10931255	0.15652																						
24	13809374	0.19773																						
25	-16216242	-.23219																						
26	2821509	0.04040																						
27	4521148	0.06474																						
28	-2417721	-.03462																						
29	-5171438	-.07405																						
30	5938417	0.08503																						
31	-7103829	-.10172																						
32	8231953	0.11787																						
33	1469510	0.02104																						
34	-17486778	-.25039																						
35	18347515	0.26271																						
36	776307	0.01112																						

5i. Identifikasi Orde ARIMAX Pecahan *Outflow* Rp 20.000,00(i). Plot ACF setelah *differencing lag-1*

Autocorrelations																								
Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1	
0	450581	1.00000																						
1	-171444	-.38050												*****		.								
2	-56307.112	-.12497												.	**	.								
3	27313.400	0.06062												.	*	.								
4	-38798.972	-.08611												.	**	.								
5	27561.679	0.06117												.	*	.								
6	-25909.752	-.05750												.	*	.								
7	27333.125	0.06066												.	*	.								
8	-25887.294	-.05745												.	*	.								
9	22758.789	0.05051												.	*	.								
10	-125603	-.27876												*****		.								
11	65481.745	0.14533												.		***								
12	205350	0.45575												.		*****								
13	-145299	-.32247												*****		.								
14	6825.409	0.01515												.		.								
15	-16303.514	-.03618												.	*	.								
16	20496.141	0.04549												.		*	.							
17	-34187.352	-.07587												.	**	.								
18	17840.122	0.03959												.	*	.								
19	-4358.681	-.00967												.		.								
20	-11800.773	-.02619												.	*	.								
21	11902.808	0.02642												.	*	.								
22	-154777	-.34351												*****		.								
23	252066	0.55942												.		*****								
24	-27673.008	-.06142												.	*	.								
25	-76585.820	-.16997												.	***	.								
26	36801.827	0.08168												.		**	.							
27	-34715.387	-.07705												.	**	.								
28	27087.293	0.06012												.	*	.								
29	-35379.627	-.07852												.	**	.								
30	13160.875	0.02921												.	*	.								
31	-21060.040	-.04674												.	*	.								
32	35026.870	0.07774												.	**	.								
33	-44481.350	-.09872												.	**	.								
34	-68516.858	-.15206												.	***	.								
35	211812	0.47009												.		*****								
36	-91875.951	-.20391												.	***	.								

(ii). Plot PACF setelah *differencing lag-1*

Partial Autocorrelations																						
Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
1	-0.38050										*****	.										
2	-0.31541										*****	.										
3	-0.15833										***	.										
4	-0.21617										***	.										
5	-0.10756										**	.										
6	-0.16972										***	.										
7	-0.06280										*	.										
8	-0.13934										**	.										
9	-0.04319										*	.										
10	-0.46693										*****	.										
11	-0.42843										*****	.										
12	0.24806										.	*****										
13	0.14393										.	***										
14	0.11728										.	**										
15	0.01820										.	.										
16	0.18489										.	****										
17	0.03625										.	*	.									
18	0.09700										.	**	.									
19	-0.01381										.	.	.									
20	-0.05791										.	*	.									
21	0.05002										.	*	.									
22	-0.32092										*****	.										
23	0.18428										.	****										
24	-0.03904										.	*	.									
25	-0.01029										.	.	.									
26	0.00464										.	.	.									
27	0.03650										.	*	.									
28	0.01278										.	.	.									
29	0.05063										.	*	.									
30	-0.04932										.	*	.									
31	-0.09273										.	**	.									
32	0.00392										.	.	.									
33	0.17976										.	****										
34	-0.06970										.	*	.									
35	-0.05316										.	*	.									
36	0.01346										.	.	.									

5j. Identifikasi Orde ARIMAX Pecahan *Outflow* Rp 10.000,00

(i). Plot ACF

Autocorrelations													
Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0
0	200625	1.00000											*****
1	36658.135	0.18272										.	****
2	-19222.762	-.09581								.	**	.	
3	-23824.893	-.11875								.	**	.	
4	-16895.179	-.08421								.	**	.	
5	-2015.929	-.01005								.	.	.	
6	-17162.076	-.08554								.	**	.	
7	-4316.653	-.02152								.	.	.	
8	-16398.131	-.08174								.	**	.	
9	-21243.789	-.10589								.	**	.	
10	-15653.176	-.07802								.	**	.	
11	81540.503	0.40643								.	.	.	*****
12	123173	0.61394								.	.	.	*****
13	-1693.512	-.00844								.	.	.	
14	-23247.470	-.11587								.	**	.	
15	-24580.787	-.12252								.	**	.	
16	-12145.975	-.06054								.	*	.	
17	-16606.976	-.08278								.	**	.	
18	-6941.965	-.03460								.	*	.	
19	-10124.712	-.05047								.	*	.	
20	-16233.916	-.08092								.	**	.	
21	-19394.241	-.09667								.	**	.	
22	-10058.089	-.05013								.	*	.	
23	102497	0.51089								.	.	.	*****
24	40388.734	0.20131								.	.	.	****
25	-12506.493	-.06234								.	*	.	
26	-16762.974	-.08355								.	**	.	
27	-18043.789	-.08994								.	**	.	
28	-8102.431	-.04039								.	*	.	
29	-18392.036	-.09167								.	**	.	
30	-9379.241	-.04675								.	*	.	
31	-9391.468	-.04681								.	*	.	
32	-13470.923	-.06714								.	*	.	
33	-20157.800	-.10047								.	**	.	
34	2872.200	0.01432								.	.	.	
35	64275.488	0.32038								.	.	.	*****
36	1231.141	0.00614								.	.	.	

5k. Identifikasi Orde ARIMAX Pecahan *Outflow* Rp 5.000,00

(i). Plot ACF

[illegible]

(ii). Plot PACF

[illegible]

51. Identifikasi Orde ARIMAX Pecahan *Outflow* Rp 1.000,00(i). Plot ACF setelah *differencing lag-1*

Autocorrelations																							
Lag	Covariance	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
0	10510.001	1.00000																					
1	-3701.264	-.35217												*****		.							
2	-1431.498	-.13620												***		.							
3	96.202626	0.00915												.		.							
4	52.241688	0.00497												.		.							
5	32.828470	0.00312												.		.							
6	-433.654	-.04126												.	*	.							
7	137.303	0.01306												.	.	.							
8	-78.596694	-.00748												.	.	.							
9	-149.281	-.01420												.	.	.							
10	-2650.091	-.25215												*****		.							
11	1110.661	0.10568												.	**	.							
12	6037.256	0.57443												.		*****							
13	-3798.586	-.36143												*****		.							
14	-458.807	-.04365												.	*	.							
15	56.981069	0.00542												.	.	.							
16	370.634	0.03526												.	*	.							
17	-254.478	-.02421												.	.	.							
18	-225.500	-.02146												.	.	.							
19	104.070	0.00990												.	.	.							
20	-130.442	-.01241												.	.	.							
21	-298.460	-.02840												.	*	.							
22	-3619.385	-.34438												*****		.							
23	5791.461	0.55104												.		*****							
24	501.787	0.04774												.	*	.							
25	-2212.453	-.21051												.	****	.							
26	-92.397581	-.00879												.	.	.							
27	174.922	0.01664												.	.	.							
28	245.086	0.02332												.	.	.							
29	-415.880	-.03957												.	*	.							
30	96.526603	0.00918												.	.	.							
31	-118.965	-.01132												.	.	.							
32	-4.126337	-.00039												.	.	.							
33	-943.449	-.08977												.	**	.							
34	-2757.790	-.26240												.	*****	.							
35	7006.588	0.66666												.		*****							
36	-2167.485	-.20623												.	****	.							

Lampiran 6 Output SAS Uji Asumsi Model ARIMAX per Pecahan *Inflow* dan *Outflow* Uang Kartal

6a. Output SAS Uji Asumsi Model ARIMAX Pecahan *Inflow* Rp 100.000,00

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.04	3	0.1688	-0.106	0.119	-0.009	-0.005	0.017	0.107
12	12.22	9	0.2010	0.080	-0.058	-0.070	-0.002	-0.060	0.177
18	18.41	15	0.2416	-0.093	0.124	-0.060	0.115	-0.015	0.014
24	29.22	21	0.1088	-0.058	-0.077	-0.088	-0.093	0.152	-0.136
30	32.04	27	0.2304	-0.014	0.091	-0.062	0.062	0.026	0.005
36	33.56	33	0.4400	-0.002	0.000	-0.063	-0.051	-0.009	-0.042
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.92559	Pr < W	<0.0001				
Kolmogorov-Smirnov		D	0.11536	Pr > D	<0.0100				
Cramer-von Mises		W-Sq	0.29605	Pr > W-Sq	<0.0050				
Anderson-Darling		A-Sq	1.774589	Pr > A-Sq	<0.0050				

6b. Output SAS Uji Asumsi Model ARIMAX Pecahan *Inflow* Rp 50.000,00

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.64	3	0.2000	-0.072	-0.116	0.087	-0.026	-0.010	0.084
12	6.02	9	0.7378	-0.031	-0.056	0.006	-0.064	-0.038	0.000
18	7.96	15	0.9255	0.071	-0.031	0.012	0.017	0.041	-0.068
24	16.80	21	0.7233	-0.082	-0.001	-0.037	-0.035	0.074	-0.200
30	21.87	27	0.7438	-0.135	0.072	-0.063	0.045	0.032	-0.008
36	24.57	33	0.8551	-0.034	0.047	0.022	-0.035	0.085	-0.051
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.951562	Pr < W	0.0001				
Kolmogorov-Smirnov		D	0.082624	Pr > D	0.0267				
Cramer-von Mises		W-Sq	0.320471	Pr > W-Sq	<0.0050				
Anderson-Darling		A-Sq	1.907009	Pr > A-Sq	<0.0050				

6c. *Output SAS Uji Asumsi Model ARIMAX Pecahan Inflow Rp 20.000,00*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.63	5	0.4630	-0.091	-0.030	0.165	0.018	-0.004	-0.024
12	7.43	11	0.7629	-0.017	0.015	0.137	-0.043	0.006	0.017
18	9.41	17	0.9265	-0.084	0.026	0.033	-0.022	-0.002	0.070
24	18.31	23	0.7403	-0.046	0.003	-0.116	0.044	0.151	-0.138
30	21.56	29	0.8380	-0.053	0.115	0.005	-0.068	-0.014	-0.006
36	29.09	35	0.7485	-0.019	-0.045	-0.019	0.064	-0.007	-0.192

Tests for Normality			
Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W 0.941938	Pr < W	<0.0001
Kolmogorov-Smirnov	D 0.104751	Pr > D	<0.0100
Cramer-von Mises	W-Sq 0.291728	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq 1.769415	Pr > A-Sq	<0.0050

6d. *Output SAS Uji Asumsi Model ARIMAX Pecahan Inflow Rp 10.000,00*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.45	2	0.0241	0.038	-0.156	0.111	0.082	0.020	-0.097
12	10.37	8	0.2397	0.028	-0.028	0.073	-0.018	-0.083	0.077
18	13.72	14	0.4709	0.084	-0.109	-0.025	-0.023	-0.044	-0.018
24	24.18	20	0.2346	0.017	-0.132	-0.133	0.105	-0.034	-0.134
30	29.39	26	0.2937	0.070	0.106	-0.030	-0.050	0.047	0.096
36	41.98	32	0.1115	-0.020	-0.044	-0.107	0.103	-0.036	-0.209

Tests for Normality			
Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W 0.975084	Pr < W	0.0164
Kolmogorov-Smirnov	D 0.078383	Pr > D	0.0470
Cramer-von Mises	W-Sq 0.12754	Pr > W-Sq	0.0477
Anderson-Darling	A-Sq 0.818026	Pr > A-Sq	0.0354

6e. *Output SAS Uji Asumsi Model ARIMAX Pecahan Inflow Rp 5.000,00*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.24	1	0.0220	-0.090	-0.065	0.131	0.089	0.026	0.019
12	11.14	7	0.1324	0.105	0.028	0.115	-0.024	0.034	0.118
18	12.26	13	0.5065	0.059	-0.050	0.012	-0.006	-0.021	-0.030
24	25.51	19	0.1444	0.041	-0.175	-0.173	0.061	0.010	-0.130
30	30.43	25	0.2086	0.148	-0.027	-0.052	-0.025	-0.022	-0.056
36	42.07	31	0.0886	-0.088	0.097	-0.151	0.007	0.096	-0.124
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.989651	Pr < W	0.4315				
Kolmogorov-Smirnov		D	0.034117	Pr > D	>0.1500				
Cramer-von Mises		W-Sq	0.026475	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.192934	Pr > A-Sq	>0.2500				

6f. *Output SAS Uji Asumsi Model ARIMAX Pecahan Inflow Rp 2.000,00*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.39	4	0.2499	-0.031	0.115	-0.240	-0.011	-0.107	0.090
12	11.05	10	0.3540	0.002	0.015	0.020	0.120	0.237	-0.103
18	17.04	16	0.3827	0.029	-0.246	0.063	-0.115	-0.023	-0.020
24	29.78	22	0.1240	0.067	-0.166	0.123	-0.031	0.053	-0.285
30	33.36	28	0.2227	-0.078	-0.113	0.043	0.010	0.053	-0.089
36	46.07	34	0.0810	-0.028	0.139	-0.041	0.058	-0.216	-0.096
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.976351	Pr < W	0.3722				
Kolmogorov-Smirnov		D	0.1159	Pr > D	0.0756				
Cramer-von Mises		W-Sq	0.070132	Pr > W-Sq	>0.2500				
Anderson-Darling		A-Sq	0.381294	Pr > A-Sq	>0.2500				

6g. *Output SAS Uji Asumsi Model ARIMAX Pecahan Inflow Rp 1.000,00*

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.86	1	0.0275	0.085	-0.013	0.130	-0.067	-0.062	-0.056
12	11.98	7	0.1012	-0.149	0.001	-0.126	-0.037	-0.059	-0.084
18	17.43	13	0.1803	0.111	0.108	-0.033	-0.014	0.082	-0.067
24	25.08	19	0.1578	-0.038	0.091	0.187	0.025	-0.049	0.026
30	28.62	25	0.2802	0.038	0.051	0.050	0.079	-0.003	-0.090
36	31.30	31	0.4510	-0.024	-0.001	-0.088	0.059	-0.036	-0.045

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.961303	Pr < W	0.0009
Kolmogorov-Smirnov	D	0.084569	Pr > D	0.0216
Cramer-von Mises	W-Sq	0.145281	Pr > W-Sq	0.0275
Anderson-Darling	A-Sq	1.000731	Pr > A-Sq	0.0126

6h. *Output SAS Uji Asumsi Model ARIMAX Pecahan Outflow Rp 100.000,00*

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.53	2	0.0232	-0.084	0.125	-0.108	0.014	0.138	0.038
12	15.03	8	0.0586	0.152	0.021	-0.150	-0.061	-0.055	0.005
18	16.82	14	0.2660	0.016	-0.039	-0.057	-0.049	-0.054	-0.039
24	30.98	20	0.0554	0.124	-0.111	0.049	-0.237	0.045	-0.032
30	32.87	26	0.1660	0.005	-0.032	-0.024	0.015	-0.077	-0.057
36	34.98	32	0.3283	0.085	-0.033	0.053	-0.002	0.021	-0.020

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.972792	Pr < W	0.0098
Kolmogorov-Smirnov	D	0.078353	Pr > D	0.0472
Cramer-von Mises	W-Sq	0.178136	Pr > W-Sq	0.0098
Anderson-Darling	A-Sq	1.034845	Pr > A-Sq	0.0098

6i. *Output SAS Uji Asumsi Model ARIMAX Pecahan Outflow Rp 50.000,00*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.02	2	0.3648	-0.077	0.006	0.038	0.068	-0.021	-0.050
12	5.59	8	0.6933	0.137	-0.024	-0.051	0.022	0.044	-0.031
18	9.86	14	0.7727	-0.128	0.084	0.021	0.024	-0.013	0.064
24	13.08	20	0.8741	0.004	-0.029	0.074	-0.081	0.008	-0.084
30	16.38	26	0.9265	-0.037	-0.060	-0.074	0.037	0.001	-0.088
36	38.75	32	0.1912	-0.015	0.058	-0.100	-0.204	0.259	0.043

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.957261	Pr < W	0.0004
Kolmogorov-Smirnov	D	0.085502	Pr > D	0.0195
Cramer-von Mises	W-Sq	0.266782	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	1.585024	Pr > A-Sq	<0.0050

6j. *Output SAS Uji Asumsi Model ARIMAX Pecahan Outflow Rp 20.000,00*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	9.88	3	0.0196	-0.087	-0.208	0.031	-0.139	-0.034	-0.021
12	14.40	9	0.1087	0.063	0.049	-0.112	0.004	0.101	0.050
18	20.07	15	0.1692	-0.050	-0.081	-0.041	-0.018	-0.044	0.156
24	26.30	21	0.1954	0.014	-0.116	0.035	-0.063	0.042	-0.135
30	31.33	27	0.2579	0.082	-0.070	-0.014	0.124	0.033	-0.041
36	41.39	33	0.1498	-0.080	0.030	-0.040	-0.037	0.211	0.032

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W	0.977591	Pr < W	0.0289
Kolmogorov-Smirnov	D	0.064649	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.115258	Pr > W-Sq	0.0734
Anderson-Darling	A-Sq	0.749274	Pr > A-Sq	0.0497

6k. *Output SAS Uji Asumsi Model ARIMAX Pecahan Outflow Rp 10.000,00*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.85	4	0.0971	0.197	0.077	0.045	0.021	0.102	0.002
12	11.24	10	0.3389	0.038	0.017	0.031	-0.038	0.085	0.108
18	13.34	16	0.6479	-0.077	0.020	0.012	0.036	-0.032	0.071
24	21.09	22	0.5153	0.006	0.012	0.072	-0.030	0.128	-0.158
30	21.92	28	0.7851	0.015	0.010	0.004	-0.005	-0.025	0.062
36	43.47	34	0.1280	-0.006	-0.027	-0.007	-0.001	-0.199	-0.278
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.841682	Pr < W		<0.0001			
Kolmogorov-Smirnov		D	0.14384	Pr > D		<0.0100			
Cramer-von Mises		W-Sq	0.975176	Pr > W-Sq		<0.0050			
Anderson-Darling		A-Sq	5.518487	Pr > A-Sq		<0.0050			

8l. *Output SAS Uji Asumsi Model ARIMAX Pecahan Outflow Rp 5.000,00*

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	0.97	4	0.9147	0.045	-0.010	0.042	0.003	0.056	-0.005
12	9.73	10	0.4645	0.015	0.025	0.058	-0.027	0.136	0.190
18	11.56	16	0.7737	0.017	-0.015	-0.017	-0.066	-0.081	0.017
24	33.04	22	0.0614	-0.058	-0.010	0.018	-0.096	0.321	-0.128
30	34.77	28	0.1768	-0.035	-0.002	-0.010	-0.045	-0.076	-0.032
36	37.61	34	0.3072	-0.014	0.052	0.051	-0.088	-0.034	0.036
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.87693	Pr < W		<0.0001			
Kolmogorov-Smirnov		D	0.125643	Pr > D		<0.0100			
Cramer-von Mises		W-Sq	0.610281	Pr > W-Sq		<0.0050			
Anderson-Darling		A-Sq	3.870939	Pr > A-Sq		<0.0050			

6m. *Output SAS Uji Asumsi Model ARIMAX Pecahan Outflow*
Rp 2.000,00

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.08	6	0.9119	0.058	0.139	-0.086	-0.048	-0.011	0.053
12	12.33	12	0.4196	-0.128	-0.013	-0.029	-0.180	-0.021	-0.309
18	14.83	18	0.6733	-0.024	-0.040	-0.112	-0.120	0.049	0.015
24	18.41	24	0.7827	0.016	0.015	0.049	0.087	0.151	-0.061
30	21.15	30	0.8833	0.058	-0.018	0.028	0.002	0.057	-0.122
36	23.86	36	0.9398	0.118	-0.039	-0.034	0.017	-0.034	0.039
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.911343	Pr < W	0.0007				
Kolmogorov-Smirnov		D	0.107913	Pr > D	0.1166				
Cramer-von Mises		W-Sq	0.136967	Pr > W-Sq	0.0361				
Anderson-Darling		A-Sq	1.036848	Pr > A-Sq	0.0093				

6n. *Output SAS Uji Asumsi Model ARIMAX Pecahan Outflow*
Rp 1.000,00

Autocorrelation Check of Residuals									
To Lag	Chi- Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.98	2	0.0503	0.125	-0.137	-0.006	-0.077	-0.034	-0.053
12	11.04	8	0.1994	-0.089	-0.127	-0.060	-0.073	0.042	0.032
18	15.10	14	0.3716	-0.152	0.006	0.012	0.039	0.018	0.047
24	30.64	20	0.0602	0.022	0.038	0.174	-0.081	-0.142	-0.194
30	34.34	26	0.1267	-0.053	0.038	0.064	0.063	0.060	0.077
36	45.48	32	0.0576	0.046	0.089	0.016	-0.199	0.110	0.014
Tests for Normality									
Test		--Statistic--		-----p Value-----					
Shapiro-Wilk		W	0.870745	Pr < W	<0.0001				
Kolmogorov-Smirnov		D	0.151642	Pr > D	<0.0100				
Cramer-von Mises		W-Sq	0.775689	Pr > W-Sq	<0.0050				
Anderson-Darling		A-Sq	4.304683	Pr > A-Sq	<0.0050				

Lampiran 7 Estimasi Parameter Model ARIMAX per Pecahan
Inflow dan Outflow Uang Kartal

7a. Estimasi Parameter Model ARIMAX Pecahan *Inflow* Rp
50.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA([23])	θ_{23}	-0,582	0,11	-5,10	<0,0001
AR(1)	ϕ_1	-0,522	0,08	-6,91	<0,0001
AR([12])	ϕ_{12}	0,268	0,08	3,41	0,0007
T_t^*	β	-1,034	6,03	-0,17	0,8638
$M_{1,t}$	γ_1	6575,800	1165,50	5,64	<0,0001
$M_{2,t}$	γ_2	-5898,400	1161,40	-5,08	<0,0001
$M_{3,t}$	γ_3	209,353	1139,30	0,18	0,8542
$M_{4,t}$	γ_4	-243,326	1144,60	-0,21	0,8317
$M_{5,t}$	γ_5	-366,477	1145,40	-0,32	0,7490
$M_{6,t}$	γ_6	-237,686	1148,60	-0,21	0,8361
$M_{7,t}$	γ_7	2201,500	1158,20	1,90	0,0573
$M_{8,t}$	γ_8	-505,418	1200,40	-0,42	0,6737
$M_{9,t}$	γ_9	-1849,800	1231,80	-1,50	0,1332
$M_{10,t}$	γ_{10}	-208,594	1227,90	-0,17	0,8651
$M_{11,t}$	γ_{11}	-4147,400	1244,60	-3,33	0,0009
$M_{12,t}$	γ_{12}	-2303,200	1197,90	-1,92	0,0545
$V_{1,t}$	δ_1	14415,900	2151,10	6,70	<0,0001
$V_{2,t}$	δ_2	11708,600	1848,60	6,33	<0,0001
$V_{3,t}$	δ_3	6901,700	1811,20	3,81	<0,0001
$V_{4,t}$	δ_4	1386,100	1517,80	0,91	0,3611
$V_{1,t+1}$	δ_5	-5061,100	1798,90	-2,81	0,0049
$V_{2,t+1}$	δ_6	-5113,800	1735,00	-2,95	0,0032
$V_{3,t+1}$	δ_7	332,953	1841,50	0,18	0,8565
$V_{4,t+1}$	δ_8	9077,000	1910,90	4,75	<0,0001

7b. Estimasi Parameter Model ARIMAX Pecahan *Inflow* Rp 20.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA(1)	θ_1	0,755	0,070	10,75	<0,0001
T_t^*	β	0,115	0,155	0,74	0,4597
$M_{1,t}$	γ_1	74,539	83,854	0,89	0,3740
$M_{2,t}$	γ_2	38,573	82,362	0,47	0,6395
$M_{3,t}$	γ_3	-10,731	82,388	-0,13	0,8964
$M_{4,t}$	γ_4	-11,951	82,405	-0,15	0,8847
$M_{5,t}$	γ_5	6,601	82,424	0,08	0,9362
$M_{6,t}$	γ_6	-25,975	82,449	-0,32	0,7527
$M_{7,t}$	γ_7	-21,458	82,471	-0,26	0,7947
$M_{8,t}$	γ_8	-27,091	86,810	-0,31	0,7550
$M_{9,t}$	γ_9	-0,351	88,204	0,00	0,9968
$M_{10,t}$	γ_{10}	-78,777	90,308	-0,87	0,3830
$M_{11,t}$	γ_{11}	75,862	90,463	0,84	0,4017
$M_{12,t}$	γ_{12}	-101,749	85,473	-1,19	0,2339
$V_{1,t}$	δ_1	432,121	166,899	2,59	0,0096
$V_{2,t}$	δ_2	307,494	132,447	2,32	0,0203
$V_{3,t}$	δ_3	367,694	133,831	2,75	0,0060
$V_{4,t}$	δ_4	47,03158	159,744	0,29	0,7684
$V_{1,t+1}$	δ_5	-462,269	156,846	-2,95	0,0032
$V_{2,t+1}$	δ_6	-249,094	136,784	-1,82	0,0686
$V_{3,t+1}$	δ_7	-483,643	134,143	-3,61	0,0003
$V_{4,t+1}$	δ_8	-145,044	163,459	-0,89	0,3749

7c. Estimasi Parameter Model ARIMAX Pecahan *Inflow* Rp
10.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA(1)	θ_1	0,600	0,082	7,28	<0,0001
AR([11])	ϕ_{11}	0,402	0,085	4,72	<0,0001
AR([12])	ϕ_{12}	0,258	0,087	2,97	0,0030
AR([23])	ϕ_{23}	0,227	0,110	2,06	0,0390
T_t^*	β	-0,032	0,157	-0,20	0,8377
$M_{1,t}$	γ_1	97,951	31,144	3,15	0,0017
$M_{2,t}$	γ_2	-130,218	31,413	-4,15	<0,0001
$M_{3,t}$	γ_3	-32,795	31,116	-1,05	0,2919
$M_{4,t}$	γ_4	-67,868	30,959	-2,19	0,0284
$M_{5,t}$	γ_5	-48,023	30,916	-1,55	0,1203
$M_{6,t}$	γ_6	-41,779	30,857	-1,35	0,1758
$M_{7,t}$	γ_7	22,709	30,892	0,74	0,4623
$M_{8,t}$	γ_8	-18,965	32,273	-0,59	0,5568
$M_{9,t}$	γ_9	-31,383	33,900	-0,93	0,3546
$M_{10,t}$	γ_{10}	-108,902	32,872	-3,31	0,0009
$M_{11,t}$	γ_{11}	-140,226	34,105	-4,11	<0,0001
$M_{12,t}$	γ_{12}	-136,978	33,018	-4,15	<0,0001
$V_{1,t}$	δ_1	431,965	70,662	6,11	<0,0001
$V_{2,t}$	δ_2	258,212	59,986	4,30	<0,0001
$V_{3,t}$	δ_3	111,258	51,744	2,15	0,0315
$V_{4,t}$	δ_4	-9,878	45,006	-0,22	0,8263
$V_{1,t+1}$	δ_5	162,994	51,442	3,17	0,0015
$V_{2,t+1}$	δ_6	378,688	49,232	7,69	<0,0001
$V_{3,t+1}$	δ_7	502,134	56,940	8,82	<0,0001
$V_{4,t+1}$	δ_8	683,265	67,140	10,18	<0,0001

7d. Estimasi Parameter Model ARIMAX Pecahan *Inflow* Rp 5.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA([23])	θ_{23}	-0,402	0,124	-3,24	0,0012
AR(1)	ϕ_1	0,617	0,070	8,83	<0,0001
AR([11])	ϕ_{11}	0,380	0,089	4,27	<0,0001
AR([12])	ϕ_{12}	0,244	0,103	2,37	0,0176
AR([13])	ϕ_{13}	-0,401	0,082	-4,91	<0,0001
T_t^*	β	1,315	0,744	1,77	0,0772
$M_{1,t}$	γ_1	356,947	75,957	4,70	<0,0001
$M_{2,t}$	γ_2	284,832	74,459	3,83	0,0001
$M_{3,t}$	γ_3	282,208	73,688	3,83	0,0001
$M_{4,t}$	γ_4	241,990	73,262	3,30	0,001
$M_{5,t}$	γ_5	213,915	73,1482	2,92	0,0035
$M_{6,t}$	γ_6	201,667	73,233	2,75	0,0059
$M_{7,t}$	γ_7	232,909	73,335	3,18	0,0015
$M_{8,t}$	γ_8	288,872	74,153	3,90	<0,0001
$M_{9,t}$	γ_9	327,051	75,101	4,35	<0,0001
$M_{10,t}$	γ_{10}	314,868	75,749	4,16	<0,0001
$M_{11,t}$	γ_{11}	284,291	77,375	3,67	0,0002
$M_{12,t}$	γ_{12}	261,114	77,599	3,36	0,0008
$V_{1,t}$	δ_1	138,542	48,851	2,84	0,0046
$V_{2,t}$	δ_2	-13,925	44,730	-0,31	0,7556
$V_{3,t}$	δ_3	-71,627	39,363	-1,82	0,0688
$V_{4,t}$	δ_4	-111,672	32,270	-3,46	0,0005
$V_{1,t+1}$	δ_5	175,773	31,541	5,57	<0,0001
$V_{2,t+1}$	δ_6	122,066	39,803	3,07	0,0022
$V_{3,t+1}$	δ_7	115,312	43,880	2,63	0,0086
$V_{4,t+1}$	δ_8	129,439	44,371	2,92	0,0035

7e. Estimasi Parameter Model ARIMAX Pecahan *Inflow* Rp
2.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
AR(1)	ϕ_1	0,815	0,085	9,60	<0,0001
AR([12])	ϕ_{12}	-0,192	0,089	-2,17	0,02970
T_t^*	β	4,597	0,985	4,67	<0,0001
$M_{1,t}$	γ_1	79,806	32,454	2,46	0,0139
$M_{2,t}$	γ_2	52,988	32,400	1,64	0,1020
$M_{3,t}$	γ_3	43,248	32,395	1,34	0,1819
$M_{4,t}$	γ_4	16,257	32,433	0,50	0,6162
$M_{5,t}$	γ_5	1,344	32,398	0,04	0,9669
$M_{6,t}$	γ_6	-16,817	32,176	-0,52	0,6012
$M_{7,t}$	γ_7	-31,253	31,627	-0,99	0,3231
$M_{8,t}$	γ_8	32,046	31,585	1,01	0,3103
$M_{9,t}$	γ_9	158,469	34,237	4,63	<0,0001
$M_{10,t}$	γ_{10}	160,125	32,016	5,00	<0,0001
$M_{11,t}$	γ_{11}	92,045	32,201	2,86	0,0043
$M_{12,t}$	γ_{12}	61,560	32,701	1,88	0,0598
$V_{2,t}$	δ_1	-101,810	23,596	-4,31	<0,0001
$V_{3,t}$	δ_2	-107,683	23,129	-4,66	<0,0001
$V_{4,t}$	δ_3	-101,794	34,302	-2,97	0,0030
$V_{2,t+1}$	δ_4	13,082	22,910	0,57	0,5680
$V_{3,t+1}$	δ_5	-95,389	22,563	-4,23	<0,0001
$V_{4,t+1}$	δ_6	-150,443	35,042	-4,29	<0,0001

7f. Estimasi Parameter Model ARIMAX Pecahan *Inflow* Rp 1.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA(1)	θ_1	0,593	0,095	6,26	<0,0001
AR(1)	ϕ_1	-0,186	0,079	-2,36	0,0182
AR([11])	ϕ_{11}	0,168	0,085	1,97	0,0488
AR([12])	ϕ_{12}	0,540	0,079	6,83	<0,0001
AR([23])	ϕ_{23}	0,331	0,092	3,61	0,0003
T_t^*	β	-0,027	0,035	-0,77	0,4390
$M_{1,t}$	γ_1	24,850	9,797	2,54	0,0112
$M_{2,t}$	γ_2	-8,198	10,063	-0,81	0,4153
$M_{3,t}$	γ_3	0,546	9,824	0,06	0,9557
$M_{4,t}$	γ_4	-19,467	9,771	-1,99	0,0463
$M_{5,t}$	γ_5	-10,813	9,766	-1,11	0,2682
$M_{6,t}$	γ_6	-20,176	9,812	-2,06	0,0398
$M_{7,t}$	γ_7	-7,751	9,877	-0,78	0,4326
$M_{8,t}$	γ_8	-2,375	10,281	-0,23	0,8173
$M_{9,t}$	γ_9	-16,254	10,627	-1,53	0,1262
$M_{10,t}$	γ_{10}	4,962	10,404	0,48	0,6334
$M_{11,t}$	γ_{11}	22,375	10,670	2,10	0,0360
$M_{12,t}$	γ_{12}	3,349	10,508	0,32	0,7500
$V_{2,t}$	δ_1	35,453	24,442	1,45	0,1469
$V_{3,t}$	δ_2	10,929	20,717	0,53	0,5978
$V_{4,t}$	δ_3	-10,146	17,006	-0,60	0,5508
$V_{2,t+1}$	δ_4	-28,090	13,095	-2,15	0,0319
$V_{3,t+1}$	δ_5	25,590	14,229	1,80	0,0721
$V_{4,t+1}$	δ_6	40,103	15,900	2,52	0,0117

7g. Estimasi Parameter Model ARIMAX Pecahan *Outflow* Rp
100.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA(1)	θ_1	0,703	0,076	9,26	<0,0001
AR(1)	ϕ_1	-0,176	0,055	-3,20	0,0014
AR([12])	ϕ_{12}	0,758	0,065	11,60	<0,0001
AR([13])	ϕ_{13}	0,307	0,068	4,50	<0,0001
T_t^*	β	1,988	5,018	0,40	0,6920
		-			
$M_{1,t}$	γ_1	17230,100	2951,100	-5,84	<0,0001
$M_{2,t}$	γ_2	5274,000	3046,700	1,73	0,0834
$M_{3,t}$	γ_3	1408,900	3072,900	0,46	0,6466
$M_{4,t}$	γ_4	1242,800	2961,400	0,42	0,6747
$M_{5,t}$	γ_5	1422,300	2972,600	0,48	0,6323
$M_{6,t}$	γ_6	386,633	2996,600	0,13	0,8973
$M_{7,t}$	γ_7	-883,590	3090,400	-0,29	0,7749
$M_{8,t}$	γ_8	-5802,800	3218,800	-1,80	0,0714
$M_{9,t}$	γ_9	-1299,500	3153,600	-0,41	0,6803
$M_{10,t}$	γ_{10}	-897,857	3133,300	-0,29	0,7745
$M_{11,t}$	γ_{11}	-436,575	3129,900	-0,14	0,8891
$M_{12,t}$	γ_{12}	5470,00	3037,400	1,80	0,0717
$V_{2,t}$	δ_1	-1476,600	2545,100	-0,58	0,5618
$V_{3,t}$	δ_2	10533,900	3262,200	3,23	0,0012
$V_{4,t}$	δ_3	15552,900	4039,000	3,85	0,0001
$V_{2,t+1}$	δ_4	10212,900	4674,000	2,19	0,0289
$V_{3,t+1}$	δ_5	12935,100	4791,300	2,70	0,0069
$V_{4,t+1}$	δ_6	2466,000	4109,600	0,60	0,5485

7h. Estimasi Parameter Model ARIMAX Pecahan *Outflow* Rp 50.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA(1)	θ_1	0,855	0,064	13,39	<0,0001
AR([12])	ϕ_{12}	-0,482	0,112	-4,31	<0,0001
AR([13])	ϕ_{13}	0,299	0,098	3,05	0,0023
AR([23])	ϕ_{23}	0,394	0,109	3,63	0,0003
T_t^*	β	-0,708	3,366	-0,21	0,8334
$M_{1,t}$	γ_1	-13807,200	1791,100	-7,71	<0,0001
$M_{2,t}$	γ_2	1628,200	1793,700	0,91	0,3640
$M_{3,t}$	γ_3	2401,200	1788,800	1,34	0,1795
$M_{4,t}$	γ_4	182,529	1789,200	0,10	0,9187
$M_{5,t}$	γ_5	1001,600	1788,100	0,56	0,5754
$M_{6,t}$	γ_6	1868,400	1790,900	1,04	0,2968
$M_{7,t}$	γ_7	-1357,100	1893,600	-0,72	0,4736
$M_{8,t}$	γ_8	-671,107	1938,900	-0,35	0,7292
$M_{9,t}$	γ_9	-4037,500	1905,800	-2,12	0,0341
$M_{10,t}$	γ_{10}	-2516,700	1928,200	-1,31	0,1918
$M_{11,t}$	γ_{11}	-223,144	1884,400	-0,12	0,9057
$M_{12,t}$	γ_{12}	7854,900	1801,000	4,36	<0,0001
$V_{2,t}$	δ_1	-9217,100	2740,400	-3,36	0,0008
$V_{3,t}$	δ_2	4529,500	2930,400	1,55	0,1222
$V_{4,t}$	δ_3	4883,000	3253,000	1,50	0,1333
$V_{2,t+1}$	δ_4	5274,100	3170,700	1,66	0,0962
$V_{3,t+1}$	δ_5	18234,000	3480,100	5,24	<0,0001
$V_{4,t+1}$	δ_6	6643,200	3071,500	2,16	0,0306

7i. Estimasi Parameter Model ARIMAX Pecahan *Outflow* Rp 20.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA([23])	θ_{23}	-0,808	0,179	-4,51	<0,0001
AR(1)	ϕ_1	-0,345	0,080	-4,29	<0,0001
AR([12])	ϕ_{12}	0,273	0,084	3,24	0,0012
T_t^*	β	0,238	0,891	0,27	0,7898
$M_{1,t}$	γ_1	-341,586	141,338	-2,42	0,0157
$M_{2,t}$	γ_2	-296,993	140,254	-2,12	0,0342
$M_{3,t}$	γ_3	54,2668	136,271	0,40	0,6905
$M_{4,t}$	γ_4	79,334	136,894	0,58	0,5622
$M_{5,t}$	γ_5	31,209	137,139	0,23	0,8200
$M_{6,t}$	γ_6	228,090	139,010	1,64	0,1008
$M_{7,t}$	γ_7	44,379	146,074	0,30	0,7613
$M_{8,t}$	γ_8	-287,329	151,987	-1,89	0,0587
$M_{9,t}$	γ_9	-348,289	149,117	-2,34	0,0195
$M_{10,t}$	γ_{10}	-131,891	152,799	-0,86	0,3880
$M_{11,t}$	γ_{11}	-234,086	147,268	-1,59	0,1119
$M_{12,t}$	γ_{12}	249,140	141,684	1,76	0,0787
$V_{2,t}$	δ_1	-1459,300	213,348	-6,84	<0,0001
$V_{3,t}$	δ_2	-595,110	220,577	-2,70	0,0070
$V_{4,t}$	δ_3	195,394	240,968	0,81	0,4174
$V_{2,t+1}$	δ_4	639,237	256,437	2,49	0,0127
$V_{3,t+1}$	δ_5	1680,500	286,898	5,86	<0,0001
$V_{4,t+1}$	δ_6	1111,300	244,483	4,55	<0,0001

7j. Estimasi Parameter Model ARIMAX Pecahan *Outflow* Rp 10.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA([12])	θ_{12}	-0,461	0,145	-3,19	0,0014
MA([23])	θ_{23}	-0,542	0,141	-3,84	0,0001
T_t^*	β	0,273	0,758	0,36	0,7192
$M_{1,t}$	γ_1	489,907	100,701	4,86	<0,0001
$M_{2,t}$	γ_2	381,886	100,061	3,82	0,0001
$M_{3,t}$	γ_3	407,311	100,285	4,06	<0,0001
$M_{4,t}$	γ_4	464,054	100,753	4,61	<0,0001
$M_{5,t}$	γ_5	475,107	101,259	4,69	<0,0001
$M_{6,t}$	γ_6	573,680	101,431	5,66	<0,0001
$M_{7,t}$	γ_7	712,752	105,983	6,73	<0,0001
$M_{8,t}$	γ_8	655,320	110,238	5,94	<0,0001
$M_{9,t}$	γ_9	188,410	108,739	1,73	0,0832
$M_{10,t}$	γ_{10}	204,448	112,220	1,82	0,0685
$M_{11,t}$	γ_{11}	237,647	108,6609	2,19	0,0287
$M_{12,t}$	γ_{12}	477,785	104,175	4,59	<0,0001
$V_{2,t}$	δ_1	-217,031	128,291	-1,69	0,0907
$V_{3,t}$	δ_2	200,574	127,695	1,57	0,1162
$V_{4,t}$	δ_3	603,044	148,408	4,06	<0,0001
$V_{2,t+1}$	δ_4	1185,600	151,458	7,83	<0,0001
$V_{3,t+1}$	δ_5	1186,500	162,611	7,30	<0,0001
$V_{4,t+1}$	δ_6	-0,461	0,145	-3,19	0,0014

7k. Estimasi Parameter Model ARIMAX Pecahan *Outflow* Rp 5.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA([11])	θ_{11}	-0,353	0,148	-2,39	0,0167
MA([24])	θ_{24}	0,647	0,217	2,97	0,0029
T_t^*	β	0,843	0,449	1,88	0,0602
$M_{1,t}$	γ_1	219,775	44,334	4,96	<0,0001
$M_{2,t}$	γ_2	189,555	45,009	4,21	<0,0001
$M_{3,t}$	γ_3	215,926	45,148	4,78	<0,0001
$M_{4,t}$	γ_4	255,424	45,526	5,61	<0,0001
$M_{5,t}$	γ_5	283,504	45,326	6,25	<0,0001
$M_{6,t}$	γ_6	386,832	44,695	8,65	<0,0001
$M_{7,t}$	γ_7	462,804	49,056	9,43	<0,0001
$M_{8,t}$	γ_8	349,138	51,607	6,77	<0,0001
$M_{9,t}$	γ_9	69,746	54,760	1,27	0,2028
$M_{10,t}$	γ_{10}	36,569	56,661	0,65	0,5187
$M_{11,t}$	γ_{11}	49,652	54,888	0,90	0,3657
$M_{12,t}$	γ_{12}	221,016	47,0321	4,70	<0,0001
$V_{2,t}$	δ_1	-132,159	159,062	-0,83	0,4060
$V_{3,t}$	δ_2	421,755	138,886	3,04	0,0024
$V_{4,t}$	δ_3	613,182	132,887	4,61	<0,0001
$V_{2,t+1}$	δ_4	1055,000	125,438	8,41	<0,0001
$V_{3,t+1}$	δ_5	1282,400	158,607	8,09	<0,0001
$V_{4,t+1}$	δ_6	1743,500	132,200	13,19	<0,0001

71. Estimasi Parameter Model ARIMAX Pecahan *Outflow* Rp 2.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
T_t^*	β	2,160	0,406	5,32	<0,0001
$M_{1,t}$	γ_1	64,563	24,992	2,58	0,0098
$M_{2,t}$	γ_2	58,323	25,160	2,32	0,0204
$M_{3,t}$	γ_3	66,052	25,333	2,61	0,0091
$M_{4,t}$	γ_4	83,127	25,511	3,26	0,0011
$M_{5,t}$	γ_5	119,554	25,694	4,65	<0,0001
$M_{6,t}$	γ_6	136,345	25,883	5,27	<0,0001
$M_{7,t}$	γ_7	146,193	31,019	4,71	<0,0001
$M_{8,t}$	γ_8	-286,555	39,804	-7,20	<0,0001
$M_{9,t}$	γ_9	-39,989	27,089	-1,48	0,1399
$M_{10,t}$	γ_{10}	15,7472	23,377	0,67	0,5005
$M_{11,t}$	γ_{11}	27,631	23,577	1,17	0,2412
$M_{12,t}$	γ_{12}	87,224	23,782	3,67	0,0002
$V_{2,t}$	δ_1	283,778	41,895	6,77	<0,0001
$V_{3,t}$	δ_2	980,177	41,895	23,4	<0,0001
$V_{4,t}$	δ_3	1631,600	59,664	27,35	<0,0001
$V_{2,t+1}$	δ_4	1478,000	43,335	34,11	<0,0001
$V_{3,t+1}$	δ_5	658,069	43,335	15,19	<0,0001
$V_{4,t+1}$	δ_6	153,528	54,278	2,83	0,0047

7m. Estimasi Parameter Model ARIMAX Pecahan *Outflow* Rp
1.000,00

Variabel	Parameter	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
MA(1)	θ_1	0,567	0,081	6,99	<0,0001
MA([23])	θ_{23}	0,275	0,096	2,88	0,0040
AR([12])	ϕ_{12}	0,407	0,048	8,47	<0,0001
AR([23])	ϕ_{23}	0,590	0,049	12,09	<0,0001
T_t^*	β	-0,043	0,052	-0,83	0,4078
$M_{1,t}$	γ_1	-33,028	37,125	-0,89	0,3737
$M_{2,t}$	γ_2	-47,041	37,729	-1,25	0,2125
$M_{3,t}$	γ_3	-28,275	37,992	-0,74	0,4567
$M_{4,t}$	γ_4	-25,683	38,224	-0,67	0,5016
$M_{5,t}$	γ_5	-23,126	38,179	-0,61	0,5447
$M_{6,t}$	γ_6	-12,790	38,211	-0,33	0,7378
$M_{7,t}$	γ_7	-12,062	38,303	-0,31	0,7528
$M_{8,t}$	γ_8	6,329	38,548	0,16	0,8696
$M_{9,t}$	γ_9	1,638	38,539	0,04	0,9661
$M_{10,t}$	γ_{10}	3,292	40,064	0,08	0,9345
$M_{11,t}$	γ_{11}	-79,181	39,677	-2,00	0,0460
$M_{12,t}$	γ_{12}	-15,812	37,491	-0,42	0,6732
$V_{2,t}$	δ_1	-63,120	32,594	-1,94	0,0528
$V_{3,t}$	δ_2	208,729	39,515	5,28	<0,0001
$V_{4,t}$	δ_3	255,550	49,678	5,14	<0,0001
$V_{2,t+1}$	δ_4	290,856	54,961	5,29	<0,0001
$V_{3,t+1}$	δ_5	269,312	59,988	4,49	<0,0001
$V_{4,t+1}$	δ_6	86,704	51,339	1,69	0,0912

Lampiran 8 *Output SAS Hasil Ramalan Out-Sample Inflow Rp 100.000,00*

Obs	Forecast	95% Confidence Limit		Actual	Residual
2	1417,547	5367,337	-9102,241	11937,335	5308,464
3	2888,305	4725,705	-6373,906	12150,517	5134,965
⋮	⋮	⋮	⋮	⋮	⋮
108	12554,496	3378,898	5931,979	19177,014	8000,276
109	18044,247	3378,847	11421,827	24666,666	21279,111
110	14101,678	3378,790	7479,372	20723,984	14505,648
111	13489,801	3378,725	6867,621	20111,981	12418,293
112	11347,468	3378,658	4725,420	17969,515	11611,607
113	12135,590	3378,590	5513,674	18757,505	15110,680
114	12500,253	3378,526	5878,464	19122,042	11973,262
115	14464,686	3378,467	7843,013	21086,360	16709,593
116	22965,956	3378,415	16344,385	29587,528	28496,082
117	20024,740	3378,369	13403,258	26646,222	19000,506
118	15348,895	3378,329	8727,492	21970,298	12183,329
119	14811,055	3378,292	8189,724	21432,386	17624,512
120	12393,960	3378,258	5772,697	19015,223	9684,584
121	22223,789	3378,223	15602,594	28844,985	34358,548
122	20272,383	3378,187	13651,259	26893,507	18657,726
123	17377,111	3378,148	10756,062	23998,159	15301,908
124	18020,876	3378,106	11399,909	24641,842	15794,919
125	17542,140	3378,061	10921,262	24163,018	15467,820
126	16139,465	3378,014	9518,680	22760,250	14813,426
127	15203,730	3377,964	8583,042	21824,418	14646,643
128	42966,165	3377,915	36345,573	49586,756	51638,586
129	19786,412	3377,866	13165,915	26406,908	15292,210
130	19818,766	3377,820	13198,360	26439,172	18076,254
131	16637,634	3377,777	10017,313	23257,955	17271,331
132	17734,140	3377,736	11113,898	24354,382	9995,215
133	23396,360	3369,540	16792,183	.	.
134	13946,976	3441,591	7201,582	.	.
135	13461,914	3512,164	6578,198	.	.
136	16064,076	3581,347	9044,764	.	.
⋮	⋮	⋮	⋮	⋮	⋮
166	31333,541	4774,646	21975,408	.	.
167	35093,827	4792,168	25701,352	.	.
168	30755,442	4809,625	21328,749	.	.

Lampiran 9 *Syntax* SSA untuk Data *Inflow* Pecahan Rp 100.000,00 (dengan R)

```
library (Rssa)
data <- read.csv('E:/ data_inflow.csv', header=TRUE, sep=";")
data <- data[,1]


Yt <- ts(data, start=c(2003, 1), frequency=12)
Yt
s1 <- ssa(Yt)
s1
plot(s1)
plot(s1, type = "series", groups = as.list(1:12), ylim=c(-10500,32500))
parestimate(s1, groups=list(2:3), method = "esprit")
parestimate(s1, groups=list(4:5), method = "esprit")
parestimate(s1, groups=list(8:9), method = "esprit")
parestimate(s1, groups=list(10:11), method = "esprit")

r <- reconstruct(s1, groups = list(Trend = c(1,7,12), Seasonality =
c(2:5,8:11)))
trend <- r$Trend
trend
plot(trend, ylim=c(-20,80), col="blue")
seasonality <- r$Seasonality
seasonality
plot(seasonality, ylim=c(-20,80), col="brown")
noise <- residuals(r)
noise
plot(noise, ylim=c(-20,80), col="black")



output1=cbind(trend, seasonality, noise)
write.csv(output1,file='E:/SSA/outputY1.csv')
```

Lampiran 10 Dekomposisi SSA per Pecahan *Inflow* dan *Outflow*

10a. Dekomposisi SSA Pecahan *Inflow* Rp 50.000,00



Plot Nilai Singular Data *Inflow*
Pecahan Rp 50.000,00




Plot *Eigentriple* Utama dan Hasil Rekonstruksi

Hasil Pengelompokan *Eigentriple*

Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1
<i>Seasonality</i>	4,5,6,7,8,9,10,11,14,15,19,20
<i>Noise</i>	2,3,12,13,16,17,18,21,22,....,50


10b. Dekomposisi SSA Pecahan *Inflow* Rp 20.000,00




Plot *Eigentriple* Utama dan Hasil Rekonstruksi

Hasil Pengelompokan <i>Eigentriple</i>	
Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1
<i>Seasonality</i>	4,5,6,7,8,9,10,11
<i>Noise</i>	2,3,12,13,....,50

10c. Dekomposisi SSA Pecahan *Inflow* Rp 10.000,00



Plot Nilai Singular Data *Inflow*
Pecahan Rp 10.000,00




Plot *Eigentriple* Utama dan Hasil Rekonstruksi

Hasil Pengelompokan *Eigentriple*

Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1
<i>Seasonality</i>	5,6,7,8,12,13,14,15
<i>Noise</i>	2,3,4,9,10,11,16,17,...,50


10d. Dekomposisi SSA Pecahan *Inflow* Rp 5.000,00




Plot *Eigentriple* Utama dan Hasil Rekonstruksi

Hasil Pengelompokan <i>Eigentriple</i>	
Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1
<i>Seasonality</i>	4,5,7,8,10,11,12,13
<i>Noise</i>	6,9,2,3,14,15,16,....,50

10e. Dekomposisi SSA Pecahan *Inflow* Rp 2.000,00



Plot Nilai Singular Data *Inflow*
Pecahan Rp 2.000,00




Plot *Eigentriple* Utama dan Hasil Rekonstruksi

Hasil Pengelompokan *Eigentriple*

Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1
<i>Seasonality</i>	4,5,7,8,9,10,11,12
<i>Noise</i>	2,3,6,13,14,...,50


10f. Dekomposisi SSA Pecahan *Inflow* Rp 1.000,00



Plot *Eigentruple* Utama dan Hasil Rekonstruksi

Hasil Pengelompokan <i>Eigentruple</i>	
Kelompok	<i>Eigentruple</i>
<i>Trend</i>	1
<i>Seasonality</i>	2,3,5,6,7,8,9,10
<i>Noise</i>	4,11,12,...,50


10g. Dekomposisi SSA Pecahan *Outflow* Rp 100.000,00



Plot *Eigentriple* Utama dan Hasil Rekonstruksi

Hasil Pengelompokan <i>Eigentriple</i>	
Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1
<i>Seasonality</i>	2,3,4,5,11,12,15,16,17,18
<i>Noise</i>	6,7,8,9,10,19,...,50


10h. Dekomposisi SSA Pecahan *Outflow* Rp 50.000,00



Plot *Eigentriple* Utama dan Hasil Rekonstruksi

Hasil Pengelompokan <i>Eigentriple</i>	
Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1,2
<i>Seasonality</i>	3,4,5,6,8,9
<i>Noise</i>	7,10,11,...,50


10i. Dekomposisi SSA Pecahan *Outflow* Rp 20.000,00



Plot *Eigentriple* Utama dan Hasil Rekonstruksi

Hasil Pengelompokan <i>Eigentriple</i>	
Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1
<i>Seasonality</i>	7,8,9,10,11,12
<i>Noise</i>	2,3,4,5,6,13,14,...,50


10j. Dekomposisi SSA Pecahan *Outflow* Rp 10.000,00



Plot *Eigentriple* Utama dan Hasil Rekonstruksi

Hasil Pengelompokan <i>Eigentriple</i>	
Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1
<i>Seasonality</i>	6,7,8,9,10,11,15,16
<i>Noise</i>	2,3,4,5,12,13,14,17,28,...,50


10k. Dekomposisi SSA Pecahan *Outflow* Rp 5.000,00



Plot *Eigentriple* Utama dan Hasil Rekonstruksi

Hasil Pengelompokan <i>Eigentriple</i>	
Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1
<i>Seasonality</i>	6,7,8,9,10,11,12,13,14,15
<i>Noise</i>	2,3,4,5,16,17,18,19,....,50

101. Dekomposisi SSA Pecahan *Outflow* Rp 2.000,00




Plot *Eigentriple* Utama dan Hasil Rekonstruksi


Hasil Pengelompokan *Eigentriple*

Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1
<i>Seasonality</i>	6,7,8,9,10,11,12,13,14,15,16,17,18,19
<i>Noise</i>	2,3,4,5,20,21,...,50

10m. Dekomposisi SSA Pecahan *Outflow* Rp 1.000,00



Plot Nilai Singular Data
Outflow Pecahan Rp 1.000,00




Plot *Eigentriple* Utama dan Hasil Rekonstruksi


Hasil Pengelompokan <i>Eigentriple</i>	
Kelompok	<i>Eigentriple</i>
<i>Trend</i>	1
<i>Seasonality</i>	2,3,4,5,6,7,9,10,11,12
<i>Noise</i>	8,13,14,....,50



Lampiran 11 Plot PACF (a) *Trend*, (b) *Noise*, (c) *Seasonality* dan (d) *Differencing* Musiman Stasioner untuk Masing-Masing Kelompok pada Pecahan *Inflow* dan *Outflow*

11a. Plot PACF Pecahan *Inflow* Rp 50.000,00




11b. Plot PACF Pecahan *Inflow* Rp 20.000,00






11c. Plot PACF Pecahan *Inflow* Rp 10.000,0011d. Plot PACF Pecahan *Inflow* Rp 5.000,00

11e. Plot PACF Pecahan *Inflow* Rp 2.000,00




11f. Plot PACF Pecahan *Inflow* Rp 1.000,00




11g. Plot PACF Pecahan *Outflow* Rp 100.000,0011h. Plot PACF Pecahan *Outflow* Rp 50.000,00


11i. Plot PACF Pecahan *Outflow* Rp 20.000,00




11j. Plot PACF Pecahan *Outflow* Rp 10.000,00




11k. Plot PACF Pecahan *Outflow* Rp 5.000,00



11i. Plot PACF Pecahan *Outflow* Rp 2.000,00



11m. Plot PACF Pecahan *Outflow* Rp 1.000,00



Lampiran 12 Syntax ANFIS untuk Data *Inflow* Pecahan Rp 100.000,00 (dengan MATLAB)

12a. Syntax ANFIS untuk Kelompok *Trend*

```
x=load('E:/SSA/outputY1.txt');
x1=x(:,1);

% Data In-Sample
x_1=x1(5:131);
x_2=x1(1:127);
x_3=[x_1 x_2];

% Data Out-Sample
x_11=x1(132:167);
x_21=x1(128:163);
x_41=[x_11 x_21];

% Output
y_1=x1(6:132);
y_2=x1(133:168);

% Proses ANFIS
epoch_n=50;
numMFs=2;
mfType='gaussmf';
in_fis1=genfis1([x_3 y_1],numMFs,mfType);
out_fis1=anfis([x_3 y_1],in_fis1,epoch_n);

% Tahap Peramalan
y_hat1=evalfis(x_3,out_fis1);
yt1=x1;
for i=[133:168];
    yt1(i)=evalfis([yt1(i-1) yt1(i-5)], out_fis1);
end;
y_hat2=yt1(133:168);

% Tahap Residual
er_in1=y_1-y_hat1;
er_out1=y_2-y_hat2;

% Evaluasi Model
rmse_in1 = sqrt(mean(er_in1.*er_in1));
rmse_out1 = sqrt(mean(er_out1.*er_out1));
mape_in1 = mean(abs(er_in1./y_1))*100;
mape_out1 = mean(abs(er_out1./y_2))*100;
smape_in1 = mean(abs(er_in1./((y_1+y_hat1)/2)))*100;
smape_out1 = mean(abs(er_out1./((y_2+y_hat2)/2)))*100;
smdape_in1 = median(abs(er_in1./((y_1+y_hat1)/2)))*100;
smdape_out1 = median(abs(er_out1./((y_2+y_hat2)/2)))*100

ruleview(out_fis1)
showfis(out_fis1)
xlswrite('E:/ANFIS/for_trend1_in.csv',y_hat1)
xlswrite('E:/ANFIS/for_trend1_out.csv',y_hat2)
```

12b. Syntax ANFIS untuk Kelompok *Seasonality*

```
x=load('E:/SSA/outputY1.txt');
x1=x(:,2);

% Data In-Sample
x_1=x1(1:120);

% Data Out-Sample
x_11=x1(121:156);

% Output
y_1=x1(13:132);
y_2=x1(133:168);

% Proses ANFIS
epoch_n=50;
numMFs=2;
mfType='pimf';
in_fis1=genfis1([x_1 y_1],numMFs,mfType);
out_fis1=anfis([x_1 y_1],in_fis1,epoch_n);

% Tahap Peramalan
y_hat1=evalfis(x_1,out_fis1);
yt1=x1;
for i=[133:168];
yt1(i)=evalfis(yt1(i-12), out_fis1);
end;
y_hat2=yt1(133:168);

% Tahap Residual
er_in1=y_1-y_hat1;
er_out1=y_2-y_hat2;

% Evaluasi Model
rmse_in1 = sqrt(mean(er_in1.*er_in1));
rmse_out1 = sqrt(mean(er_out1.*er_out1));
mape_in1 = mean(abs(er_in1./y_1))*100;
mape_out1 = mean(abs(er_out1./y_2))*100;
smape_in1 = mean(abs(er_in1./((y_1+y_hat1)/2)))*100;
smape_out1 = mean(abs(er_out1./((y_2+y_hat2)/2)))*100;
smdape_in1 = median(abs(er_in1./((y_1+y_hat1)/2)))*100;
smdape_out1 = median(abs(er_out1./((y_2+y_hat2)/2)))*100;

% Save yhat
xlswrite('E:/ANFIS/for_seasonall_in.csv',y_hat1)
xlswrite('E:/ANFIS/for_seasonall_out.csv',y_hat2)
```

12c. Syntax ANFIS untuk Kelompok Noise

```

x=load('E:/SSA/outputY1.txt');
x1=x(:,3);

% Data In-Sample
x_1=x1(1:130);

% Data Out-Sample
x_11=x1(131:166);

% Output
y_1=x1(3:132);
y_2=x1(133:168);

% Proses ANFIS
epoch_n=50;
numMFs=2;
mfType='gaussmf';
in_fis1=genfis1([x_1 y_1],numMFs,mfType);
out_fis1=anfis([x_1 y_1],in_fis1,epoch_n);

% Tahap Peramalan
y_hat1=evalfis(x_1,out_fis1);
yt1=x1;
for i=[133:168];
yt1(i)=evalfis(yt1(i-2),out_fis1);
end;
y_hat2=yt1(133:168);

% Tahap Residual
er_in1=y_1-y_hat1;
er_out1=y_2-y_hat2;

% Evaluasi Model
rmse_in1 = sqrt(mean(er_in1.*er_in1));
rmse_out1 = sqrt(mean(er_out1.*er_out1));
mape_in1 = mean(abs(er_in1./y_1))*100;
mape_out1 = mean(abs(er_out1./y_2))*100;
smape_in1 = mean(abs(er_in1./((y_1+y_hat1)/2)))*100;
smape_out1 = mean(abs(er_out1./((y_2+y_hat2)/2)))*100;
smdape_in1 = median(abs(er_in1./((y_1+y_hat1)/2)))*100;
smdape_out1 = median(abs(er_out1./((y_2+y_hat2)/2)))*100

% Save yhat
xlswrite('E:/ANFIS/for_noise1_in.csv',y_hat1)
xlswrite('E:/ANFIS/for_noise1_out.csv',y_hat2)

```

Lampiran 13 Hasil Dekomposisi SSA dan Hasil Ramalan ANFIS pada Pecahan *Inflow* Rp 100.000,00

No	<i>Trend</i>	<i>Seasonality</i>	<i>Noise</i>	<i>Forecast Trend</i>	<i>Forecast Seasonality</i>	<i>Forecast Noise</i>
1	3020,601	258,065	4387,579	-	-	-
2	3033,534	-2088,624	4363,554	-	-	-
3	3030,568	980,659	1123,737	-	-	2555,272
4	3023,640	282,177	2454,376	-	-	2549,565
5	3012,822	-1422,580	3839,432	-	-	1396,164
6	3000,667	-126,066	2735,530	3018,926	-	1966,940
7	2990,894	690,446	2799,277	3001,520	-	2415,676
8	2984,205	-730,646	3630,016	2990,351	-	2069,808
9	2995,096	-416,305	3512,403	2983,721	-	2092,277
10	3019,418	258,845	3129,980	2999,122	-	2356,933
11	3039,597	-383,499	287,3286	3031,210	-	2322,571
12	3057,350	1176,249	6400,442	3057,953	-	2203,834
13	3072,534	-910,920	4419,305	3081,188	322,606	968,503
⋮	⋮	⋮	⋮	⋮	⋮	⋮
121	16598,050	8761,695	8998,803	16593,522	4665,477	2696,151
122	16867,992	4394,449	-2604,716	16881,243	4579,918	20,758
123	17145,917	-316,501	-1527,508	17154,845	453,235	3219,253
124	17433,237	-1442,591	-195,727	17436,641	-1058,083	-842,990
125	17727,386	-2330,939	71,373	17726,694	-1093,720	-117,520
126	18030,063	-2633,911	-582,726	18025,114	-1749,700	699,136
127	18341,599	-5403,684	1708,727	18326,991	-5544,128	850,013
128	18667,965	19747,546	13223,075	18637,692	11043,759	472,430
129	18951,293	-1009,024	-2650,060	18962,483	7433,410	1664,110
130	19246,343	-6054,564	4884,475	19252,692	-7043,457	3731,505
131	19548,134	-4900,318	2623,514	19554,166	-3846,104	-874,556
132	19859,130	-6590,262	-3273,654	19862,771	-5934,556	2665,401
133	20191,175	14091,914	4489,322	20181,63	9863,419	2029,562
134	20496,450	3291,878	-1030,618	20501,716	5002,908	-1315,737
135	20811,518	-963,136	-2969,066	20822,094	-327,931	1799,764
136	21134,525	-2235,423	-778,206	21143,930	-1595,483	18,879
137	21464,539	-4368,770	-921,807	21468,534	-2591,177	1703,422
138	21806,112	-4772,596	1340,674	21797,310	-2930,760	820,733
139	22155,146	-740,425	-12434,10	22129,133	-6035,224	1661,799
140	22540,995	23916,009	16651,164	22463,553	22086,553	1247,141
⋮	⋮	⋮	⋮	⋮	⋮	⋮
163	30595,128	35530,716	2241,358	30965,407	-7536,466	1629,271
164	30813,815	-5333,776	-2549,037	31376,121	7434,500	1629,247
165	31050,545	-6911,370	-750,816	31790,809	-1346,810	1629,270
166	31264,469	-13068,373	5958,109	32209,540	-8452,958	1629,260
167	31449,819	-13461,816	4421,777	32632,381	-6827,686	1629,270
168	31651,691	-1843,601	-9645,466	33059,399	-9207,264	1629,265

Lampiran 14 Pemilihan Model ANFIS Terbaik Pecahan *Inflow* dan *Outflow* dengan Jumlah Fungsi Keanggotaan 2

14a. Pecahan *Inflow* Rp 50.000,00

Kelompok	Jenis Fungsi	1 Input	2 Input	3 Input
<i>Trend</i>	<i>Trapezoidal</i>	3382,20	5857,30	4370,70
	<i>Gaussian</i>	4546,70	72713,00	46953,00
	<i>Phi</i>	3375,00	3247,90	212710,00
	<i>Generalized Bell</i>	4209,60	1,1e+090	2,10e+11
<i>Seasonality</i>	<i>Trapezoidal</i>	5690,30	5790,90	5440,30
	<i>Gaussian</i>	5668,50	8895,30	6595,10
	<i>Phi</i>	5685,70	5933,60	6141,60
	<i>Generalized Bell</i>	5669,10	6318,70	57600,80
<i>Noise</i>	<i>Trapezoidal</i>	3186,70	3525,30	4071,20
	<i>Gaussian</i>	3153,70	3230,10	4314,00
	<i>Phi</i>	3469,60	3670,20	4647,70
	<i>Generalized Bell</i>	3332,50	3596,90	4408,60

14b. Pecahan *Inflow* Rp 20.000,00

Kelompok	Jenis Fungsi	1 Input	2 Input	3 Input
<i>Trend</i>	<i>Trapezoidal</i>	98,98	34,59	-
	<i>Gaussian</i>	110,12	51,41	-
	<i>Phi</i>	87,32	46,53	-
	<i>Generalized Bell</i>	106,58	11,71	-
<i>Seasonality</i>	<i>Trapezoidal</i>	298,67	291,31	388,11
	<i>Gaussian</i>	296,91	332,47	205,72
	<i>Phi</i>	299,30	296,87	303,62
	<i>Generalized Bell</i>	298,44	297,86	190,76
<i>Noise</i>	<i>Trapezoidal</i>	297,38	199,83	198,08
	<i>Gaussian</i>	354,12	202,62	272,45
	<i>Phi</i>	308,82	337,22	963,05
	<i>Generalized Bell</i>	353,38	203,93	411,35

14c. Pecahan *Inflow* Rp 10.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	146,75	39,03	-
	<i>Gaussian</i>	15,80	112,44	-
	<i>Phi</i>	147,11	39,51	-
	<i>Generalized Bell</i>	18,97	56,62	-
<i>Seasonality</i>	<i>Trapezoidal</i>	265,50	318,75	1479,20
	<i>Gaussian</i>	265,03	15908,00	785760,00
	<i>Phi</i>	263,69	1120,00	1639,80
	<i>Generalized Bell</i>	264,71	2,84E+06	8,00E+11
<i>Noise</i>	<i>Trapezoidal</i>	238,22	237,57	234,67
	<i>Gaussian</i>	237,53	236,91	223,47
	<i>Phi</i>	241,06	237,63	235,81
	<i>Generalized Bell</i>	238,25	237,50	222,64

14d. Pecahan *Inflow* Rp 5.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	129,32	35,88	131,95
	<i>Gaussian</i>	274,47	71,95	36,72
	<i>Phi</i>	128,53	44,93	194,57
	<i>Generalized Bell</i>	125,25	57,70	63,22
<i>Seasonality</i>	<i>Trapezoidal</i>	214,78	540,71	1392,40
	<i>Gaussian</i>	214,41	432,19	11146,00
	<i>Phi</i>	212,89	1,21E+03	3406,30
	<i>Generalized Bell</i>	214,08	238,07	5,68E+10
<i>Noise</i>	<i>Trapezoidal</i>	193,78	191,27	230,95
	<i>Gaussian</i>	193,73	193,26	198,82
	<i>Phi</i>	194,08	192,00	216,47
	<i>Generalized Bell</i>	193,88	192,14	208,53

14e. Pecahan *Inflow* Rp 2.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	55,12	66,35	66,13
	<i>Gaussian</i>	675,23	12348,00	1829,90
	<i>Phi</i>	47,65	68,08	163,45
	<i>Generalized Bell</i>	1697,80	8,07e+23	3,92e+40
<i>Seasonality</i>	<i>Trapezoidal</i>	61,67	142,51	1438,30
	<i>Gaussian</i>	61,73	5256,40	15931,00
	<i>Phi</i>	61,57	342,94	1774,40
	<i>Generalized Bell</i>	61,92	62700,00	6,38E+26
<i>Noise</i>	<i>Trapezoidal</i>	90,76	42,13	104,94
	<i>Gaussian</i>	95,27	67,34	3319,70
	<i>Phi</i>	88,79	95,78	906,85
	<i>Generalized Bell</i>	91,13	103,79	3,22E+10

14f. Pecahan *Inflow* Rp 1.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	0,81	2,54	2,27
	<i>Gaussian</i>	0,51	0,71	0,45
	<i>Phi</i>	0,43	2,47	2,31
	<i>Generalized Bell</i>	0,45	0,51	1,34
<i>Seasonality</i>	<i>Trapezoidal</i>	11,09	147,79	6,37
	<i>Gaussian</i>	10,55	17,14	7,51
	<i>Phi</i>	12,42	34,96	7,83
	<i>Generalized Bell</i>	11,69	41,22	7,48
<i>Noise</i>	<i>Trapezoidal</i>	12,78	7,61	6,83
	<i>Gaussian</i>	12,40	8,69	6,36
	<i>Phi</i>	12,88	9,04	12,15
	<i>Generalized Bell</i>	12,59	8,38	7,98

14g. Pecahan *Outflow* Rp 100.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	7460,00	5413,60	9563,60
	<i>Gaussian</i>	868,22	9,95e+06	2,67e+08
	<i>Phi</i>	6534,60	3916,00	8929,70
	<i>Generalized Bell</i>	331,61	1524,90	76874,00
<i>Seasonality</i>	<i>Trapezoidal</i>	12436,00	12742,00	1617,40
	<i>Gaussian</i>	12437,00	13370,00	2,71e+06
	<i>Phi</i>	12446,00	12590,00	22601,00
	<i>Generalized Bell</i>	12441,00	13020,00	6,57e+08
<i>Noise</i>	<i>Trapezoidal</i>	8888,70	6492,70	6490,60
	<i>Gaussian</i>	836,70	3534,80	5,95e+06
	<i>Phi</i>	81890,00	6490,60	64910,00
	<i>Generalized Bell</i>	293,65	3293,10	8,77e+09

14h. Pecahan *Outflow* Rp 50.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	2887,50	5396,50	7035,50
	<i>Gaussian</i>	2772,10	3297,10	68576,00
	<i>Phi</i>	2892,30	447,50	19687,00
	<i>Generalized Bell</i>	2781,80	3362,80	3,12e+09
<i>Seasonality</i>	<i>Trapezoidal</i>	5694,40	5214,60	9194,20
	<i>Gaussian</i>	5703,20	5177,40	170390,00
	<i>Phi</i>	5705,10	5316,60	9791,40
	<i>Generalized Bell</i>	5709,90	5224,20	32126,00
<i>Noise</i>	<i>Trapezoidal</i>	7002,90	6900,70	71150,00
	<i>Gaussian</i>	6970,30	6960,90	7166,80
	<i>Phi</i>	6876,80	6902,40	6471,40
	<i>Generalized Bell</i>	6952,90	6912,90	6819,10

14i. Pecahan *Outflow* Rp 20.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	109,04	12,63	45,83
	<i>Gaussian</i>	127,77	54,62	37,46
	<i>Phi</i>	95,57	18,23	52,68
	<i>Generalized Bell</i>	111,95	14,07	268250,00
<i>Seasonality</i>	<i>Trapezoidal</i>	475,22	475,27	2538,80
	<i>Gaussian</i>	475,20	472,90	34154,00
	<i>Phi</i>	474,93	469,29	10966,00
	<i>Generalized Bell</i>	475,02	476,55	3,01e+15
<i>Noise</i>	<i>Trapezoidal</i>	817,61	868,92	849,59
	<i>Gaussian</i>	842,00	847,79	1183,00
	<i>Phi</i>	869,81	853,54	864,83
	<i>Generalized Bell</i>	851,87	857,08	845,28

14j. Pecahan *Outflow* Rp 10.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	91,47	109,54	90,64
	<i>Gaussian</i>	12,03	88,37	13775,00
	<i>Phi</i>	91,42	109,69	67,09
	<i>Generalized Bell</i>	10,63	1,50e+41	8,50e+09
<i>Seasonality</i>	<i>Trapezoidal</i>	614,32	626,29	4936,60
	<i>Gaussian</i>	610,99	619,56	278810,00
	<i>Phi</i>	610,48	607,97	57194,00
	<i>Generalized Bell</i>	611,56	616,05	3,47e+28
<i>Noise</i>	<i>Trapezoidal</i>	798,34	791,75	8294,20
	<i>Gaussian</i>	799,72	791,08	788,88
	<i>Phi</i>	790,92	787,26	4591,60
	<i>Generalized Bell</i>	793,94	791,01	805,37

14k. Pecahan *Outflow* Rp 5.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	99,49	43,50	142,43
	<i>Gaussian</i>	26,64	1992,80	6851,70
	<i>Phi</i>	99,45	38,22	142,36
	<i>Generalized Bell</i>	14,37	71,63	46,02
<i>Seasonality</i>	<i>Trapezoidal</i>	609,55	814,29	3707,70
	<i>Gaussian</i>	609,55	21539,00	3197,50
	<i>Phi</i>	609,57	858,89	1035,80
	<i>Generalized Bell</i>	609,56	2220,3	2,02e+20
<i>Noise</i>	<i>Trapezoidal</i>	727,81	742,86	5680,50
	<i>Gaussian</i>	728,14	759,84	11960,00
	<i>Phi</i>	728,00	754,26	53635,00
	<i>Generalized Bell</i>	728,12	754,32	1,35e+23

14l. Pecahan *Outflow* Rp 2.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	53,90	-	-
	<i>Gaussian</i>	8,28	-	-
	<i>Phi</i>	33,75	-	-
	<i>Generalized Bell</i>	8,94	-	-
<i>Seasonality</i>	<i>Trapezoidal</i>	272,86	591,52	3829,40
	<i>Gaussian</i>	272,30	12021,00	131470,00
	<i>Phi</i>	272,28	660,79	375010,00
	<i>Generalized Bell</i>	269,70	3,40E+7	3,51E+23
<i>Noise</i>	<i>Trapezoidal</i>	322,68	280,76	5905,60
	<i>Gaussian</i>	285,14	51562,00	62697,00
	<i>Phi</i>	288,42	260,92	1397,10
	<i>Generalized Bell</i>	320,20	5,49e+39	4,63e+42

14m. Pecahan *Outflow* Rp 1.000,00

Kelompok	Jenis Fungsi	1 <i>Input</i>	2 <i>Input</i>	3 <i>Input</i>
<i>Trend</i>	<i>Trapezoidal</i>	2,46	4,30	4,09
	<i>Gaussian</i>	2,68	2,62	2,99
	<i>Phi</i>	1,11	4,37	4,11
	<i>Generalized Bell</i>	2,00	1,14	1,95
<i>Seasonality</i>	<i>Trapezoidal</i>	32,79	17,00	7,70
	<i>Gaussian</i>	29,96	16,15	10,37
	<i>Phi</i>	29,88	14,99	43,18
	<i>Generalized Bell</i>	30,70	16,77	13,85
<i>Noise</i>	<i>Trapezoidal</i>	21,81	40,00	36,84
	<i>Gaussian</i>	21,96	36,39	33,33
	<i>Phi</i>	23,38	32,23	25,76
	<i>Generalized Bell</i>	23,29	34,94	30,59

Lampiran 15 Output MATLAB Estimasi Parameter Model ANFIS Tiap Pecahan *Inflow* dan *Outflow*.

15a. Estimasi Parameter ANFIS Pecahan *Inflow* Rp 100.000,00

(i). Kelompok *Trend* (Fungsi *Gaussian 2 input*)

InMFParams	[7034 2984 0 0] [7034 1.955e+004 0 0] [6522 2984 0 0] [6522 1.834e+004 0 0]
OutMFParams	[1.114 -0.1002 1.518 0] [-1.678 3.736 -55.9 0] [6.916 -7.116 -51.93 0] [0.9303 0.08369 107.2 0]

(ii). Kelompok *Seasonality* (Fungsi *Phi 1 input*)

InMFParams	[-1.772e+004 -1.12e+004 -1410 5116] [-1409 5116 1.49e+004 2.143e+004]
OutMFParams	[1.121 21.43 0 0] [1.113 114.9 0 0]

(iii). Kelompok *Noise* (*Gaussian 1 input*)

InMFParams	[8355 -6454 0 0] [8355 1.322e+004 0 0]
OutMFParams	[0.7649 1099 0 0] [0.2423 59.98 0 0]

15b. Estimasi Parameter ANFIS Pecahan *Inflow* Rp 50.000,00

(i). Kelompok *Trend*

InMFParams	[7790 8852 1.044e+004 1.151e+004] [1.044e+04 1.151e+04 1.31e+004 1.416e+004] [7850 8878 1.042e+04 1.145e+004] [1.042e+04 1.145e+04 1.299e+04 1.402e+004]
OutMFParams	[4.054 -3.067 138.4 0] [-35.89 38.94 -2.321e+004 0] [28.66 -28.45 9690 0] [1.867 -0.7382 -1347 0]

(iii). Kelompok *Noise*

InMFParams	[6522 -5778 0 0] [6522 9579 0 0]
OutMFParams	[0.4555 -1481 0 0] [0.246 3688 0 0]

(ii). Kelompok *Seasonality*

InMFParams	[9137 1.705 -6177 0] [9137 2.021 1.21e+004 0] [9137 1.324 -6177 0] [9137 2.154 1.21e+004 0] [7462 1.602 -6177 0] [7462 2.138 8748 0]
OutMFParams	[-0.1442 1.205 2.019 1.084e+004] [0.4497 -2.082 6.356 -1.448e+004] [2.399 -2.348 -0.6347 7650] [-5.653 -0.5436 -15.96 1179]

15c. Estimasi Parameter ANFIS Pecahan *Inflow* Rp 20.000,00(i). Kelompok *Trend* (Fungsi *Generalized Bell 2 input*)

InMFParams	[591.4 2.016 491.7 0]
	[591.4 1.987 1675 0]
	[635.3 1.97 512.3 0]
	[635.3 2.003 1783 0]
OutMFParams	[1.161 -0.2114 54.82 0]
	[-8.207 8.365 -1292 0]
	[4.442 -1.587 194.8 0]
	[0.9178 0.3697 -618.7 0]

(ii). Kelompok *Seasonality* (Fungsi *Gaussian 2 input*)

InMFParams	[296.1 -260.3 0 0]
	[296.5 438.3 0 0]
	[286.9 -268.3 0 0]
	[286.8 408.2 0 0]
OutMFParams	[-0.5591 -1.345 -714.4 0]
	[2.828 -2.32 1040 0]
	[-2.864 3.627 1535 0]
	[0.8247 1.096 -1314 0]

(iii). Kelompok *Noise* (Fungsi *Trapezoidal 3 input*)

InMFParams	[-1603 -1020 -145.9 437.2]
	[-145.9 436.9 1311 1894]
	[-1603 -1020 -145.8 436.9]
	[-145.2 437 1311 1894]
	[-1603 -1020 -145.8 436.7]
	[-146.3 437 1311 1894]
OutMFParams	[0.7351 -0.7976 -0.1546 -199.9]
	[-1.208 2.512 0.1309 -17.24]
	[-4.555 -3.926 -2.626 -526.2]
	[7.171 5.177 -5.786 2613]
	[2.232 1.585 1.33 76.86]
	[-6.142 1.014 2.038 937.6]
	[-7.603 2.363 2.517 3011]
	[11.94 -1.063 3.354 -5872]

15d. Estimasi Parameter ANFIS Pecahan *Inflow* Rp 10.000,00(i). Kelompok *Trend*
(*Gaussian 1*)

InMFParams	[81.5 420.7 0 0]
	[81.44 614.3 0 0]
OutMFParams	[1.039 -16.56 0 0]
	[1.033 -17.08 0 0]

(ii). Kelompok *Seasonality*
(*Phi 1*)

InMFParams	[-777 -489.7 -59.13 228.5]
	[-59.45 228 659.4 946.6]
OutMFParams	[-1.288 -33.49 0 0]
	[-0.9003 144.9 0 0]

(iii). Kelompok *Noise* (*GBell 3*)

InMFParams	[347.2 1.963 -242.2 0]
	[347.2 2.666 452.3 0]
	[347.2 1.716 -242.2 0]
	[347.2 1.785 452.3 0]
	[362.2 2.269 -242.2 0]
	[362.2 2.317 482.3 0]
OutMFParams	[0.3959 0.1887 -0.6893 -327]
	[7.499 -3.356 -6.45 1913]
	[-0.1992 0.6342 0.6763 -181]
	[-5.96 3.298 9.009 -1731]
	[-2.407 1.472 0.152 881]
	[5.052 2.721 3.357 -2083]
	[-3.117 -0.04651 3.43 844.3]
	[1.936 0.409 -1.078 -538.5]

15e. Estimasi Parameter ANFIS Pecahan *Inflow* Rp 5.000,00

(i). Kelompok *Trend* (Fungsi *Trapezoidal 2 input*)

InMFParams	[196.3 258.7 352.3 415.1]
	[351.9 414.7 508.4 570.8]
	[198.3 259.5 351.4 412.5]
	[352 412.7 504.6 565.9]
OutMFParams	[1.781 -0.7734 -2.345 0]
	[-6.327 7.225 51.64 0]
	[9.504 -8.427 -41.99 0]
	[1.923 -0.9245 0.9236 0]

(ii). Kelompok *Seasonality*

InMFParams	[-619.2 -383.5 -30.08 206.1]
	[-30.64 205.7 559.5 795.2]
OutMFParams	[-1.337 -38.63 0 0]
	[-1.037 169.6 0 0]

(iii). Kelompok *Noise*

InMFParams	[-506.9 -310 -14.51 183]
	[-14.74 182.4 477.7 674.6]
	[-506.9 -310 -14.47 182]
	[-14.44 182.4 477.7 674.6]
OutMFParams	[1.09 -0.4321 11.19 0]
	[1.833 -0.2766 33.61 0]
	[0.8757 0.4193 12.69 0]
	[0.8729 0.4718 -185.2 0]

Lampiran 16 Hasil Ramalan Pecahan *Inflow* Tahun 2017-2019 dengan Metode Peramalan Terbaik (Miliar Rupiah)

No	100000	50000	20000	10000	5000	2000	1000
1	57143,66	23046,94	858,55	523,42	524,03	276,41	19,08
2	28543,54	14227,47	475,90	694,19	533,48	266,31	14,11
3	28005,04	14671,05	836,24	979,99	461,78	200,61	15,16
4	23788,32	13903,48	-35,31	737,29	394,49	211,33	11,75
5	25413,74	16103,15	672,12	900,70	349,61	234,84	10,01
6	20490,29	14638,38	58,49	815,23	195,84	235,34	6,34
7	65959,30	27668,81	61,75	2048,31	994,16	223,20	2,40
8	28296,63	23664,27	1429,43	1880,92	1140,84	227,52	12,07
9	26936,03	22968,12	586,55	772,55	879,35	244,85	18,90
10	20404,49	22362,89	54,33	380,68	688,30	249,65	15,36
11	20295,97	19384,44	813,39	213,13	593,28	251,57	15,05
12	33336,75	18805,20	774,29	643,19	449,26	282,13	12,29
13	58296,12	28611,94	391,64	676,92	611,53	345,64	13,87
14	32115,48	18376,16	443,31	1215,95	530,19	405,29	11,44
15	30111,28	19051,21	538,19	1138,46	475,71	396,56	9,93
16	26446,65	19501,80	3031,12	1304,30	387,02	388,14	7,84
17	27644,60	19498,54	242,62	1007,59	319,92	362,10	6,05
18	22594,17	29268,18	1728,46	1284,91	263,14	337,99	2,83
19	66502,59	25257,19	2634,45	2921,30	971,47	297,43	3,63
20	31028,94	25789,81	870,24	1219,21	985,99	269,48	9,13
21	29401,55	22930,28	455,18	-658,37	838,33	265,69	12,97
22	22238,42	23016,56	397,02	709,99	718,01	263,33	10,27
23	22038,88	19207,30	574,64	261,05	616,40	259,74	9,56
24	36352,62	17420,59	606,42	1347,07	535,60	267,58	8,88
25	61143,82	25804,84	302,93	1269,67	624,40	289,45	9,61
26	34913,94	17702,92	705,69	1394,91	555,80	322,27	7,54
27	32659,50	18422,82	3106,51	320,94	506,22	373,42	7,21
28	28589,08	17965,37	6166,97	-1573,56	422,66	432,50	4,49
29	29858,30	18060,53	959,75	391,40	401,07	428,14	3,05
30	24262,66	31862,22	-16916,83	414,01	566,11	410,43	0,81
31	67646,95	27586,88	1643,27	1905,73	990,48	370,06	-0,47
32	33444,64	27738,75	-224,43	352,37	931,65	341,57	5,66
33	31610,81	24307,49	-342,47	559,58	860,98	310,37	10,41
34	23692,50	24194,32	712,71	826,57	739,35	288,81	9,41
35	23428,97	20291,54	777,61	1593,39	661,43	278,39	8,89
36	39120,00	18173,59	13026,75	1415,51	576,93	276,39	5,76

Lampiran 17 Hasil Ramalan Pecahan *Outflow* Tahun 2017-2019 dengan Metode Peramalan Terbaik (Miliar Rupiah)

No	100000	50000	20000	10000	5000	2000	1000
1	8080,06	10596,23	738,70	784,63	426,04	232,69	2,47
2	19178,66	12256,85	468,96	380,02	322,61	218,77	-19,07
3	25709,33	18844,50	591,00	676,36	351,42	229,32	9,48
4	26312,13	15713,43	697,13	642,49	824,36	259,97	-33,97
5	34165,17	19008,83	1673,57	1339,47	1288,20	554,66	6,75
6	78292,72	35039,52	3662,01	3264,24	2111,57	1902,72	18,22
7	14631,43	18814,06	1449,03	766,49	353,11	252,36	-26,02
8	27588,58	17026,38	2046,95	428,94	444,62	4,68	-13,19
9	32922,66	16595,54	1647,69	345,40	247,38	168,60	-15,97
10	26223,20	14546,69	1665,81	330,18	107,02	180,75	0,02
11	39058,49	17222,75	1697,10	379,14	334,98	202,05	-15,58
12	45382,49	22179,81	2153,41	884,15	400,90	301,06	-17,23
13	9461,07	8373,78	1682,58	689,32	512,63	254,95	-26,29
14	21068,82	9806,13	1511,00	606,80	508,18	241,02	-8,40
15	27163,01	14079,26	1634,69	649,70	496,64	251,57	-23,17
16	30012,30	15382,80	1732,88	707,18	698,51	282,23	-22,22
17	50292,45	22848,91	3352,27	2400,93	2297,39	1865,86	-6,52
18	60149,15	18559,85	3722,11	1357,43	433,96	619,76	-27,79
19	17284,27	20103,18	2176,12	991,64	758,64	274,62	-27,10
20	37843,83	20172,02	2827,83	654,07	646,89	26,93	-29,41
21	33452,75	16463,82	2123,97	327,51	357,42	190,85	-21,77
22	31511,86	17177,17	2228,12	322,11	224,41	203,00	-27,94
23	45661,16	16537,45	2160,41	384,66	331,86	224,31	-28,61
24	41366,80	25918,25	2533,30	798,43	410,33	323,31	-22,32
25	14260,84	10712,56	2088,34	755,19	489,89	277,20	-25,07
26	26024,47	14548,23	1971,63	631,03	453,07	263,28	-9,07
27	29734,30	15568,67	2080,85	673,93	468,50	273,83	-33,92
28	36237,99	17369,79	2180,96	731,41	565,98	304,48	-25,93
29	78029,97	40095,26	4388,50	2706,28	2752,05	1862,09	-21,10
30	43685,65	21916,69	2941,47	926,99	714,93	237,88	-32,67
31	24715,11	23188,29	1845,86	1015,87	801,62	296,87	-32,12
32	43402,57	19806,86	2388,03	678,30	492,13	49,19	-33,15
33	33447,67	17593,20	1532,38	351,74	284,33	213,11	-32,03
34	38402,83	17821,92	1741,11	346,34	221,83	225,26	-31,31
35	46193,45	15112,33	1580,37	408,89	300,32	246,56	-18,77
36	38940,59	24578,28	1933,60	822,66	530,00	345,57	-34,39

BIODATA PENULIS



Zuhrofatul Ulwiyah, dilahirkan di Kabupaten Malang pada 7 Juli 1996 sebagai anak pertama pasangan Abdul Karim dan Nur Hidayati. Penulis menempuh pendidikan formal di SDN Tegalsari 2, SMPN 2 Kepanjen, SMAN 1 Kepanjen hingga diterima sebagai Mahasiswa Departemen Statistika ITS melalui jalur SBMPTN pada tahun 2014 dengan NRP 1314100095 yang pada semester genap 2017 NRP penulis berubah menjadi 06211440000095. Selama masa perkuliahan, penulis aktif di beberapa organisasi yakni UKM Cinta Rebana ITS pada tahun 2014-2016 dengan jabatan terakhir sebagai bendahara umum, divisi *Professional Statistics* (PSt) HIMASTA ITS 2016-2017 sebagai tim ahli, dan Forum Islam Statistika (FORSIS) ITS 2015-2016 sebagai staff keputrian. Pada tahun 2016, penulis berkesempatan mendapatkan dana hibah PKM-M. Penulis pernah melakukan kerja praktik di Stasiun Meteorologi Klas I Juanda Surabaya. Apabila ada kritik, saran dan pertanyaan mengenai Tugas Akhir ini, pembaca dapat menghubungi penulis di nomor telepon 085101933507 atau email ke zuzuhrofatul@gmail.com.

